

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**GÖRÜNTÜ ÇÖZÜNÜRLÜĞÜNÜN OTOMATİK CİNSİYET VE YAŞ
SINIFLANDIRMASINDAKİ ETKİSİNİN ANALİZİ**

YÜKSEK LİSANS TEZİ

Betül CERİT

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Muhammed Fatih DEMİRCİ

TEMMUZ 2016

Fen Bilimleri Enstitüsü Onayı

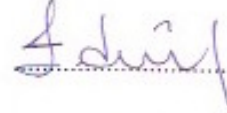
.....
Prof. Dr. Osman EROĞUL
Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylarım.

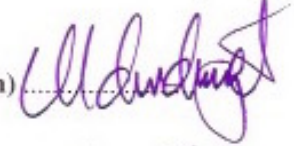
.....
Doç. Dr. Oğuz ERGİN
Anabilimdalı Başkan Vekili

TOBB ETÜ, Fen Bilimleri Enstitüsü'nün 131111021 numaralı Yüksek Lisans Öğrencisi **Betül CERİT**'in ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "**GÖRÜNTÜ ÇÖZÜNÜRLÜĞÜNÜN OTOMATİK CİNSİYET VE YAŞ SINIFLANDIRMASINDAKİ ETKİSİNİN ANALİZİ**" başlıklı tezi **27 Temmuz 2016** tarihinde aşağıda imzaları olan jüri tarafından kabul edilmiştir.

Tez Danışmanı : **Doç. Dr. Muhammed Fatih DEMİRCİ**
TOBB Ekonomik ve Teknoloji Üniversitesi



Jüri Üyeleri : **Prof. Dr. Mehmet Ali AKÇAYOL (Başkan)**
Gazi Üniversitesi



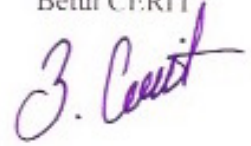
Yrd. Doç. Dr. Esra KADIOĞLU ÜRTİŞ
TOBB Ekonomi ve Teknoloji Üniversitesi



TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Betül CERİT



ÖZET

Yüksek Lisans Tezi

GÖRÜNTÜ ÇÖZÜNÜRLÜĞÜNÜN OTOMATİK CİNSİYET VE YAŞ SINIFLANDIRMASINDAKİ ETKİSİNİN ANALİZİ

Betül CERİT

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Muhammed Fatih DEMİRCİ

Tarih: Temmuz 2016

Geçmişte yapılan bir çalışmada, yüz bölgesine ait görüntüler kullanılarak, görüntü çözünürlüğünün cinsiyet tespitindeki başarıma etkisi incelenmiş ve 3x2 gibi insan gözü için hiçbir şey ifade etmeyen görüntülerde bile cinsiyete ait bilgiler olduğu ortaya koyulmuştur. Bu çalışmadan yola çıkılarak, bu tez çalışmasında, düşük çözünürlüklü görüntülerde kişinin yaşına ait bilgi bulunup bulunmadığı sorusuna cevap aranmış, bu doğrultuda 2x1, 3x2, 6x5, 8x6, 11x9, 16x13, 22x18, 45x35, 90x72, 329x264 olmak üzere, deneyler on farklı çözünürlükte, piksel parlaklık değeri, Yerel İkili Örüntüler, Çok Bloklü Yerel İkili Örüntüler ve Gradyan Yönleri Histogramları olmak üzere dört farklı öznelik ile tekrarlanarak yaş sınıflandırması yapılmış ve sonuçlar karşılaştırılmıştır. Deneylerde MORPH veri tabanı ve FG-NET Yaşlanma veri tabanı kullanılmıştır. MORPH veri tabanındaki görüntü sayısı çok fazla olduğundan ve bu durum deney sürelerini olumsuz olarak etkileyeceğinden, yaş aralığı ve cinsiyet oranı korunarak, görüntü sayısını %10'a düşürecek şekilde MORPH veri tabanının bir alt kümesi oluşturulmuş ve deneylerde bu alt küme kullanılmıştır. Deneylerde kullanılacak olan görüntüler, yüz tespiti, yüz bölgesinin

kırılması, göz orta noktalarının hizalanması, histogram eşitlenmesi gibi ön işlemlere tabi tutulmuştur. Sınıflandırma işleminde K-En Yakın Komşu ve Rastgele Orman sınıflandırıcıları kullanılmıştır. Deneyle öncelikle MORPH veri tabanına ait görüntülerde cinsiyet ve yaş ve sınıflandırması olarak ayrı ayrı gerçekleştirilmiştir. Başlangıçta yaş aralığı beş ayrık gruba bölünerek gerçekleştirilen deneyle, daha sonra daha gerçekçi yaş sınıflandırma senaryosu elde edebilmek amacıyla, ayrık yaş gruplarının birleştirilmesiyle oluşturulan iç içe yaş grupları kullanılarak tekrarlanmıştır. İç içe yaş gruplarının kullanılması daha gerçekçi sonuçlar verdiğiinden, FG-NET veri tabanında yapılan deneyle sadece iç içe yaş grubu kullanılarak gerçekleştirilmiştir. Elde edilen deney sonuçları incelendiğinde, 11x9 gibi düşük çözünürlüklerde bile cinsiyet sınıflandırma için tatmin edici başarıma ulaşıldığı fakat cinsiyet sınıflandırmasından daha karmaşık bir problem olan yaş sınıflandırması için %59.8 başarımın MORPH veri tabanına ait görüntülerde, 90x72 çözünürlüğünde yakalandığı görülmüştür. FG-NET veri tabanına ait görüntülerde elde edilen başarım ise MORPH veri tabanından daha düşük olmak üzere maksimum %57.7 dir. K-En Yakın Komşu sınıflandırıcısında en yakın görüntüler aynı kişiye ait görüntüler olduğundan, Rastgele Orman sınıflandırıcı sonuçları dikkate alınmıştır. En yüksek başarımlar piksel parlaklık değeri ve Gradyan Yönleri Histogramları öznitelikleriyle elde edilmiştir.

Anahtar Kelimeler: Cinsiyet sınıflandırma, Yaş sınıflandırma, Rastgele orman, K-En yakın komşu, Makine öğrenmesi.

ABSTRACT

Master of Science

ANALYSIS OF THE EFFECT OF IMAGE RESOLUTION ON AUTOMATIC FACE GENDER AND AGE CLASSIFICATION

Betül CERİT

TOBB University of Economics and Technology
Institute of Science
Computer Engineering Science Programme

Supervisor: Assoc. Prof. Dr. Muhammed Fatih DEMİRÇİ

Date: July 2016

In previous work, the effect of image resolution for gender classification performance was analyzed using facial images. This work revealed even very low resolution images such as 3x2, carry useful information for gender detection. Inspired by this study, this thesis seeks an answer to the question of “Do low-resolution images carry some useful information for distinguishing between age groups?”. For this purpose, four different feature types namely pixel values, Local Binary Patterns, Multi-Block Local Binary Patterns and Histogram of Oriented Gradients were employed in the experiments where each experiment was repeated using ten different image resolutions including, 2x1, 3x2, 6x5, 8x6, 11x9, 16x13, 22x18, 45x35, 90x72, 329x264. Two popular facial datasets, MORPH and FG-NET Aging databases were used for the experiments. Since the large number of images in MORPH database has negative effects on the duration of experiments, a subset of MORPH database preserving gender and age rates was used. Some preprocessing operations, e.g., face detection, cropping, aligning eye centers, histogram equalization were applied to the images prior to the classification process. K- Nearest Neighbor and Random Forests algorithms were employed separately for age and

gender classifications. Age classification experiments were conducted on MORPH database using separate age groups first. The experiments were then repeated with nested age groups to employ more realistic age classification scenarios. Since nested age groups increased the success rate, such groups were used for FG-NET only. As a result, for gender classification, satisfying results were obtained even for low resolution images such as 11x9. Since age classification is harder and more complicated than that of gender, lower age classification success rates were obtained. For age classification, maximum 59.8% success rate for MORPH database and maximum 57.7% success rate for FG-NET database were recorded. K- Nearest Neighbor results are highly affected by the different image of the same persons. Hence, Random Forest results are taken to be more realistic. In terms of feature types, maximum success rates were obtained using pixel values and Histogram of Oriented Gradients.

Keywords: Gender classification, Age classification, Random forests, K-Nearest neighbor, Machine learning.

TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren, kıymetli tecrübelerinden faydalandığım danışman hocam Doç. Dr. Muhammed Fatih Demirci'ye, tez çalıőması süresince her daim yanımda olup bana moral ve destek veren anneme çok teőekkür ederim.



İÇİNDEKİLER

Sayfa

ÖZET	iv
ABSTRACT	vi
İÇİNDEKİLER	ix
ŞEKİL LİSTESİ	xi
ÇİZELGE LİSTESİ	xiv
KISALTMALAR	xiv
RESİM LİSTESİ	xv
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	7
2.2 Yaş Tespiti	8
2.3 Yaş ve Cinsiyet Tespiti	10
2.4 Çözünürlüğe Bağlı Tespit	10
3. KULLANILAN ARAÇ, VERİ TABANI VE YÖNTEMLER	13
3.1 MORPH Veri Tabanı	13
3.2 FG-NET Yaşlanma Veri Tabanı	17
3.3 K-En Yakın Komşu Algoritması (K-EYK)	21
3.4 Rastgele Orman (RO)	23
3.5 Yerel İkili Örüntüler (Local Binary Patterns)	25
3.5.1 Orijinal yerel ikili örüntüler (YİÖ)	25
3.5.2 Değiştirilmiş yerel ikili örüntüler (modified local binary patterns)	27
3.5.3 Çok bloklu yerel ikili Örüntüler (multi block local binary patterns)	27
3.6 Gradyan Yönleri Histogramları (Histogram of Oriented Gradients)	29
3.7 Viola – Jones Yüz Tespit Algoritması	30
3.8 K - Katlamalı Çapraz Doğrulama (K- Fold Cross Validation)	32
4. DENEYSEL KURULUM	35
4.1 Yaş Aralığı Seçimi	38
4.2 Alt Örnekleme	38
4.3 Göz Orta Noktalarının Hizalanması	39
4.4 Yüz Tespiti	43
4.5 Histogram Eşitlemesi	44
4.6 Öznitelik Vektörü Temsili	44
5. DENEY SONUÇLARI VE YORUMLAR	47
5.1 Cinsiyet Sınıflandırma	47
5.1.1 K-EYK ile cinsiyet sınıflandırma	47
5.1.2 RO ile cinsiyet sınıflandırma	51
5.2 Yaş Sınıflandırma	52
5.2.1 K-EYK ile yaş sınıflandırma	53
5.2.2 RO ile yaş sınıflandırma	66

6. SONUÇ VE GELECEK ÇALIŞMALAR.....	71
KAYNAKLAR	75
ÖZGEÇMİŞ	79



ŞEKİL LİSTESİ

Sayfa

- Şekil 3.1: (a) Mavi ve turuncu olmak üzere iki farklı sınıfın bulunduğu sisteme, sınıflandırılacak olan siyah yıldızın dahil edilmesi. (b) Sınıflandırılacak olan siyah yıldızın en yakın üç adet yıldızın Öklid mesafesi ile bulunması. (c) Siyah yıldızın en yakın üç adet yıldızdan iki yıldızın turuncu, bir yıldızın mavi olması sebebiyle, çoğunluk turuncu sınıfa ait olduğundan, siyah yıldızın turuncu olarak sınıflandırılması. 22
- Şekil 3.2: (a) Sınıflandırılacak verinin rastgele alt kümelere ayrılması. (b) Alt kümelerin her birinden karar ağacı oluşturulması. (c) Verinin her bir karar ağacına göre sınıflandırılması. (d) Karar ağaçlarından çıkan sonuçların oylama yöntemiyle toplanması. (e) Verinin en çok oyu alan sınıfa dahil edilmesi..... 24
- Şekil 3.3: (a)YİÖ değeri hesaplanacak pikselin sekiz komşuluğundaki piksellerle birlikte alınması. (b) Sekiz komşuluktaki piksellerin değerlerinin merkez piksel değeriyle kıyaslanarak 1 veya 0 değeri alması. (c) Sol üst köşedeki komşu pikselden başlanarak 1 ve 0 değerlerinin yanyana yazılması ve ikili tabandan onlu tabana dönüşüm yapılması. (d) Merkezdeki pikselin yeni değerinin belirlenmesi. 26
- Şekil 3.4: (a)YİÖ değeri hesaplanacak pikselin sekiz komşuluğundaki piksellerle birlikte alınması ve sekiz komşuluktaki piksel değerlerinin ortalamasının hesaplanması. (b) Sekiz komşuluktaki piksellerin değerlerinin ortalamayla kıyaslanarak 1 veya 0 değeri alması. (c) Sol üst köşedeki komşu pikselden başlanarak 1 ve 0 değerlerinin yanyana yazılması ve ikili tabandan onlu tabana dönüşüm yapılması. (d) Merkezdeki pikselin yeni değerinin belirlenmesi. 27
- Şekil 3.5: (a) Gri seviyeli görüntü. (b) Gri seviyeli görüntünün küçük parçalara bölünmesi. (c) Her bir küçük parça için histogram oluşturulması. (d) Elde edilen tüm histogramların tek bir histogramda toplanması..... 28
- Şekil 3.6: (a) Gri seviyeli görüntünün önce hücrelere, daha sonra hücrelerden oluşan bloklara bölünmesi, blokların %50 üst üste gelecek şekilde ayarlanması. (b) Elde edilen her bir blok için gradyanların hesaplanması. (c) Her bir blok için gradyanların histogram ile temsil edilmesi. (d) Tüm histogramların arka arkaya eklenmesiyle tek bir histogram elde edilmesi..... 29
- Şekil 3.7: Haar – benzeri öznelikler. (a) Üç – dikdörtgen öznelik..... 30
- Şekil 3.8: İntegral görüntü hesaplama örneği..... 31
- Şekil 3.9: Basamaklı sınıflandırıcı yapısı. D harfi doğruyu Y harfi ise yanlış temsil etmektedir. Her adımda yola sadece doğru sonuç veren pencerelerle devam edilmektedir..... 32

Şekil 3.10: (a) Eğitim ve test kümelerinin adet ve temsilleri. (b) Her bir iterasyonda eğitim ve test kümelerinin seçilmesi ve her iterasyon sonucunun toplanıp K sayısına bölünerek ortalama başarımın elde edilmesi.....	33
Şekil 4.1: Örnek bir görüntü üzerinde MORPH veri tabanında yapılan ön işlemler.....	36
Şekil 4.2: Örnek bir görüntü üzerinde FG-NET veri tabanında yapılan ön işlemler.....	37
Şekil 4.3: MORPH veri tabanı için iç içe yaş grupları.....	38
Şekil 4.4: FG-NET veri tabanı için iç içe yaş grupları.....	38
Şekil 4.5: Görüntüdeki her bir pikselin parlaklık değeri bir matrise yazılır ve matristeki değerler soldan sağa ve yukardan aşağı okunarak tek bir satır halinde metin dosyasına yazılır.....	45
Şekil 5.1: On farklı çözünürlükte, dört farklı öznitelik için K-EYK cinsiyet sınıflandırma başarım yüzdesi grafikleri.....	50
Şekil 5.2: On farklı çözünürlük ve dört farklı öznitelik için RO ile cinsiyet sınıflandırma başarım yüzde grafiği.....	52
Şekil 5.3: 2x1 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarım yüzde grafikleri.....	57
Şekil 5.4: 3x2 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarım yüzde grafikleri.....	57
Şekil 5.5: 6x5 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarım yüzde grafikleri.....	59
Şekil 5.6: 8x6 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarım yüzde grafikleri.....	59
Şekil 5.7: 11x9 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarım yüzde grafikleri.....	61
Şekil 5.8: 16x13 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarım yüzde grafikleri.....	61
Şekil 5.9: 22x18 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarım yüzde grafikleri.....	63
Şekil 5.10: 45x36 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarım yüzde grafikleri.....	63

Şekil 5.11: 90x72 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.....	65
Şekil 5.12: 329x264 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.....	65
Şekil 5.13: On Farklı çözünürlük ve dört farklı öznitelik için (a) MORPH ayrıık yaş grubu, (b) MORPH iç içe yaş grubu, (c) FG-NET iç içe yaş grubu RO ile yaş sınıflandırma başarıım yüzde grafiğı.	68



ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1: Alt örnekleme öncesi yaş ve cinsiyet dağılımı sayı ve yüzdeleri.....	39
Çizelge 4.2: Alt örnekleme sonrası yaş ve cinsiyet dağılımı sayı ve yüzdeleri.	39
Çizelge 5.1: On farklı çözünürlükte, farklı K değerleri ve dört farklı öznitelik için K- EYK cinsiyet sınıflandırma başarımları yüzdeleri.	48
Çizelge 5.2: On farklı çözünürlük ve dört farklı öznitelik için RO cinsiyet sınıflandırma başarımları yüzdeleri.	51
Çizelge 5.3: On farklı çözünürlükte, farklı K değerleri ve dört farklı öznitelik için MORPH veri tabanı K-EYK yaş sınıflandırma başarımları yüzdeleri.	54
Çizelge 5.4: On farklı çözünürlükte farklı K değerleri ve dört farklı öznitelik için MORPH veri tabanı K- EYK iç içe yaş grupları ile yaş sınıflandırma başarımları yüzdeleri.	55
Çizelge 5.5: On farklı çözünürlükte farklı K değerleri ve dört farklı öznitelik için FG-NET veri tabanı K- EYK iç içe yaş grupları ile yaş sınıflandırma başarımları yüzdeleri.	56
Çizelge 5.6: MORPH veri tabanı ayrık yaş grubu için dört farklı özniteliğin, on farklı çözünürlükteki, RO ile yaş sınıflandırma başarımları yüzdeleri.	66
Çizelge 5.7: MORPH veri tabanı iç içe yaş grubu için dört farklı özniteliğin, on farklı çözünürlükteki, RO ile yaş sınıflandırma başarımları yüzdeleri.	67
Çizelge 5.8: FG-NET veri tabanı iç içe yaş grubu için dört farklı özniteliğin, on farklı çözünürlükteki, RO ile yaş sınıflandırma başarımları yüzdeleri.	67

KISALTMALAR

K-EYK	: K-En Yakın Komşu (K-Nearest Neighbor)
EYK	: En Yakın Komşu (Nearest Neighbor)
DVM	: Destek Vektör Makineleri (Support Vector Machines)
RO	: Rastgele Orman (Random Forests)
YİÖ	: Yerel İkili Örüntüler (Local Binary Patterns)
ÇB-YİÖ	: Çok Bloklü Yerel İkili Örüntüler
YSA	: Yapay Sinir Ağları (Artificial Neural Networks)
HoG	: Gradyan Yönleri Histogramları (Histogram of Oriented Gradients)

RESİM LİSTESİ

Sayfa

Resim 3.1: MORPH Veri tabanından görüntü örnekleri.	14
Resim 3.2: Soldan sağa, eskiden yeniye aynı kişilere ait farklı zamanda çekilmiş görüntüler.	15
Resim 3.3: Farklı aydınlanma, yüz ifadesi, kafa pozisyonu, bakış yönü örnekleri. ..	16
Resim 3.4: FG-NET yaşlanma veri tabanından görüntü örnekleri.	17
Resim 3.5: Soldan sağa, yukarıdan aşağıya, eskiden yeniye aynı erkeğin 2 - 43 yaş arası görüntüleri.	18
Resim 3.6: Soldan sağa, yukarıdan aşağıya, eskiden yeniye aynı kadının 3 – 41 yaş arası görüntüleri.	19
Resim 3.7: Farklı aydınlanma, yüz ifadesi, kafa pozisyonu, bakış yönü örnekleri. ..	20
Resim 3.8: Farklı aydınlanma koşullarında YİÖ sonuçları.	25
Resim 4.1: Göz orta noktalarının doğru bir şekilde tespit edilerek görüntünün döndürülmesi.	40
Resim 4.2: Göz orta noktalarının yanlış tespit edilmesi sebebiyle görüntünün aynı kalması.	42
Resim 4.3: Yüz bölgesinin tespit edilerek kırılması.	43
Resim 4.4: Histogram eşitlemesi işlemi için girdi, gri seviye ve çıktı görüntüleri.	44

1. GİRİŞ

İlk üretildiği zamanlarda sadece matematiksel hesaplama, veri depolama gibi temel amaçlarla kullanılan bilgisayarlar, değişen ve gelişen ihtiyaçlar doğrultusunda günden güne yenilenmiş ve her geçen gün faaliyet alanını arttırmıştır. Bilgisayarların faaliyet alanı arttıkça eldeki veriler aynı doğrultuda artmış, mevcut verilerin işlenmesi, yorumlanması, sınıflandırılması önemli bir ihtiyaç haline gelmiştir. Yorumlama, sınıflandırma gereksinimleri, tanıma, anlamlı ve anlamsız veriyi ayırt ederek anlamsız veriyi eleme gibi ihtiyaçları da beraberinde getirmiştir.

İnsanoğlu yorumlama, sınıflandırma, tanıma gibi işlemleri neredeyse doğumundan itibaren hiçbir efor sarf etmeden ve en yüksek başarıyla gerçekleştirmektedir. Yeni doğmuş bir bebek annesinin kokusunu tanıyabilmekte, bir yaşındaki bir çocuk yüzlerce insan arasından yanlış yapmaksızın annesini bulabilmektedir. İnsan gözü ve beyni tanıma ve sınıflandırma işlemi için cisimlerin veya objelerin tamamına ihtiyaç duymamaktadır. Yarısı veya yarısından daha büyük bir kısmı başka bir cisimle kapatılmış olan nesnelere dahi tanıyabilmekte, sadece ilk ve son harfleri doğru yerde olup diğer harfleri rastgele sırayla düzenlenmiş olan kelimeleri bile rahatlıkla okuyabilmektedir.

Bilgisayarlardan, sensörlerden, kameralardan sürekli ve büyük boyutlarda elde edilen verilerin insanlar tarafından tek tek incelenmesi zaman anlamında imkansız hale gelmiş, ayrıca insanın hata yapabilme ihtimali göz önünde bulundurulduğunda insana ait yukarıda belirtilen meziyetlerin bilgisayara aktarılması zaruri hale gelmiştir. Bu problemlerin çözümü için makine öğrenmesi, örüntü tanıma, bilgisayarla görü kavramları ortaya koyulmuş ve bu alanlarda büyük yol katedilmiştir.

Günümüzde gelinen noktada örüntü tanıma, makine öğrenmesi, bilgisayarla görü alanlarından uygulama örnekleri aşağıdaki gibidir.

- Aralarında belirli mesafe bulunan iki kamera yardımı ile araç plakası tanıma işlemi gerçekleştirilip aracın ortalama hız değeri hesaplanabilmektedir.

- Otomobillerde şerit takibi [1] yapılabilmekte, otomobilin şeritten çıkması durumunda sürücüye uyarı verilebilmektedir.
- Otomobillerde aracın önüne ani bir cisim çıktığında önce cismin zararlı veya zararsız olduğu görsel algıyla algılanabilmekte, cismin zararlı olmasına karar verilmesi durumunda aracın fren yapması sağlanabilmektedir [2].
- Park asistanı [3] adı verilen sistem ile aracın etrafındaki kameralar yardımıyla park yeri bulunabilmekte ve sürücüye hangi pedala basması gerektiğinin talimatı verilerek, direksiyon park asistanı sistemiyle hareket ettirilerek paralel park yapılabilir.
- Henüz prototip halinde olan Google Self - Driving Car (sürücüsüz araba) Projesiyle [4], otomobil istenilen yere sürücüye ihtiyaç duymaksızın gidebilmektedir.
- Giriş - çıkış sistemlerinde retina, parmak izi, yüz taraması yapılarak kişi tanınabilmekte, böylece güvenlik önlemi alınabilmektedir.
- Facebook'ta fotoğraf eklendiğinde kişi etiketleme işlemi sırasında görüntüdeki kişiler tanınabilmekte, doğru olup olmadığı kullanıcının onayına sunulabilmektedir.
- Masa tenisi oynayabilen robotla rakibin hamleleri gerçek zamanlı olarak tanımlanabilmekte ve karşı hamle yapılarak Masa tenisi Dünya Şampiyonu karşısında sayılar kazanılabilmektedir [5].
- Akıllı cep telefonu uygulamalarıyla kahve fincanının farklı açılardan görüntüleri çekilip gönderilerek kahve falı bakılabilmektedir [6].
- Akıllı cep telefonu uygulamaları sayesinde ilacın görüntüsü kullanılarak ilaç hakkında bilgi alınabilmektedir [7].
- Üretim yapılan fabrikalarda banttaki ürünleri takip eden bir kamera sayesinde hatalı ürün tespiti yapılabilir.
- Google'da görselle arama özelliği sayesinde yüklenen veya linki verilen görüntü kategorisi hakkında internette arama yapılabilmekte ve en yakın görüntüler elde edilebilmektedir.

- Dijital kameralarda bulunan Gülümseme Deklanşörü özelliği sayesinde kadrajdaki yüz tespit edilerek yüzde gülümseme ifadesi olduğu anda deklanşör otomatik olarak tetiklenebilmektedir.
- Cep telefonu kameralarında deklanşör belirli el işaretleriyle tetiklenebilmektedir.
- Tıbbi görüntüleme cihazlarında hastalıklı doku veya organ tespiti otomatik olarak yapılabilmektedir.

Sınıflandırmada en çok çeşitlilik gösteren, bu yüzden hala aktif çalışmaların olduğu alanlardan biri de yüz tanıma ve sınıflandırmadır.

Yüz insan vücudunda kişiye ait en önemli bilgileri tek başına barındıran önemli bir bölgedir. Tek yumurta ikizlerinin bile yüz benzerliğinin %100 olmadığı göz önünde bulundurulacak olursa, yüz, tıpkı parmak izi gibi kişiye özeldir ve ayırt edicidir diyebiliriz. Günümüzde insan yüzü yaş, cinsiyet, etnik köken, duygu durumu, karakter gibi pek çok bilginin tespiti için kullanılmaktadır. Bu yüzden bilgisayarla otomatik kişi tanıma ve sınıflandırmada en çok yüz bölgesi ile ilgilenilmiştir.

İnsan yüzünden cinsiyet tespiti gerek sadece iki farklı seçenek olmasından gerek cinsiyetler arasında daha belirleyici farklar olmasından yaş tespitine göre daha kolay bir problemdir. Yaş, insan gözüyle bile tespit edilmesi kolay olmayan bir bilgidir. Kişilerin yaşam koşulları, günlük stresleri, genetik yapıları, kötü alışkanlıkları gibi faktörler yaş tespitinde çok etkin rol oynamaktadır. Örneğin havası kirli bir şehirde yaşayan bir kişi havası temiz olan bir bölgede yaşayan yaşlılarına göre daha yaşlı görünebilir. ABD’de Case Western Reserve Üniversitesi’nde yapılan bir araştırmada [8], biri sigara içen, diğeri sigara içmeyen tek yumurta ikizlerinin fotoğrafları incelenmiş, sigara içen kişinin ikizine göre çok daha yaşlı görüldüğü tespit edilmiştir. Ayrıca kadınlarda makyaj, kadın ve erkeklerde kişiyi olduğundan daha yaşlı gösteren kır saç veya yaşlı insanların saçlarını boyatması gibi etkenler de yaş tespitini zorlaştırmaktadır.

Sürecin uzunluğu yukarıda sayılan sebeplerden dolayı kişiden kişiye farklılık gösterse de yaşlanma yapısal ve şekilsel olmak üzere iki şekilde gerçekleşmektedir. Yaşlandıkça deri elastikliğini kaybederek ciltte sarkmaların ve kırışıklıkların meydana gelmesi yapısal bir değişikliktir. Genelde 30-40 yaşlarından itibaren kişilerde bu yapısal değişiklikler meydana gelmekte, alın,göz çevresinde kırışıklıklar

oluşmakta, yanak ve boyun bölgesinde elastikliğini kaybeden deri sarkmaya başlamaktadır. Şekilsel değişiklikler ise özellikle burun ve kulaklarda göze çarpmaktadır. Kimilerine göre, bunun sebebi kulak ve burunun ömür boyu büyümeye devam etmesi iken, kimilerine göre ise insanın yaşlandıkça kemiklerinin küçülmesi, fakat kıkırdaktan oluşan burun ve kulakta böyle bir küçülme olmamasıdır.

Cinsiyet ve yaş tespiti günlük hayatta giriş – çıkış kontrol sistemlerinde, istatistiki bilgi toplayan sistemlerde veya mağaza vitrinlerine yerleştirilen kamera sayesinde markanın hangi cinsiyet ve yaş grubuna hitap ettiği tespit edilerek hedef kitle belirleme gibi ticari amaçlarla kullanılabilmesi gibi adli tıpta kişinin kimliğinin tespit edilmesinde, kriminolojide aranılan suçlu hakkında genel bilgi elde edebilmek için de kullanılabilir.

Kişilerin yaşlarının doğru bir şekilde tespit edilmesi, yüzde oluşan yaşa bağlı değişimlerin de düzgün bir şekilde tahlil edilebilmesini beraberinde getireceğinden, yaşlanmaya ait faktörler yüz görüntülerine eklenerek kişilerin yıllar sonraki görünümü öngörülebilir. Bu sayede yıllardır kayıp olan bir kişi veya yıllardır aranan bir suçluya ait eski bir görüntüden yola çıkılarak güncel görüntüye yakın sonuçlar elde edilebilir. Böylece arama alanı daraltılarak kişilerin daha kolay bulunması sağlanabilir.

Günümüzde yaş ve cinsiyet tespitini oldukça başarılı bir şekilde gerçekleştiren ürünler, yazılımlar, uygulamalar mevcuttur fakat bahsi geçen ürünler yüksek çözünürlüklü görüntülerle çalışmaktadır. Yüksek çözünürlüklü görüntüler depolama alanı, depolama maliyeti, işlem süresi göz önünde bulundurulduğunda uzun vadede işletmeci açısından dezavantaj haline gelmektedir.

Literatürdeki çalışmalar incelendiğinde, 2014 yılında Yasmina Andreu ve arkadaşlarının yaptığı çalışmada [9], görüntü çözünürlüğünün otomatik cinsiyet sınıflandırmasındaki etkisi incelenerek 3x2 çözünürlüğe sahip görüntülerin bile cinsiyeti ayırt edebilmek için önemli bilgiler içerdiği sonucuna ulaşıldığı görülmüştür. Çalışmada 2x1, 3x2, 6x5, 8x6, 11x9, 16x13, 22x18, 45x36, 90x72, 329x264 olmak üzere on farklı çözünürlükte cinsiyet tespiti başarımı incelenmiş, 22x18 ve 90x72 arasındaki çözünürlüklerle cinsiyet tespiti için optimum başarımlar elde edilmiştir. Bu çalışmadan yola çıkılarak “düşük çözünürlüklü görüntülerden yaşa ait bilgiler elde etmek mümkün müdür?” sorusuna cevap aranmaya başlanmıştır.

Literatürdeki çözünürlüğe bağlı çalışmalar incelenmiş ve çözünürlüğün yaş ve cinsiyet sınıflandırılmasındaki başarıma etkisine dair herhangi bir çalışmaya rastlanmamıştır. Düşük çözünürlüklü görüntülerden yüksek başarımlar elde etmek, depolama alanı, maliyet, işlem süresi gibi etkenlerde tasarruf sağlayacağından bu konuya yönelinmiştir.

Bu tez çalışmasında, Yasmina Andreu ve arkadaşlarının yaptığı çalışmanın bir adım ileriye taşınması hedeflenmiş, aynı çözünürlükler kullanılarak, MORPH ve FG-NET veri tabanlarındaki görüntüler çeşitli ön işlemlerden geçirilmiş ve K- En Yakın Komşu ve Rastgele Orman gibi makine öğrenmesi algoritmaları yardımı ile cinsiyet sınıflandırmasının yanı sıra yaş sınıflandırılması da yapılarak sonuçlar karşılaştırılmıştır.

Tez çalışmasının 2. Bölümünde yaş ve/veya cinsiyet tespiti üzerine literatürde yer alan çalışmalar incelenecektir. 3. Bölümde öznelik çıkarımında ve makine öğrenmesi aşamasında faydalanılacak yöntem, veri tabanları ve araçlar anlatılacaktır. 4. Bölümde görüntülerin tabii tutulduğu ön işlemlerden bahsedilecektir. 5. Bölümde yapılan deneyler ve elde edilen deney sonuçları ele alınacaktır. Son olarak 6. Bölümde tez çalışması ve deney sonuçları genel olarak yorumlanacak ve gelecekte yapılması planlanan çalışmalardan bahsedilecektir.



2. LİTERATÜR TARAMASI

Literatürde yüz görüntülerinden yaş ve cinsiyet tespitine birlikte rastlandığı gibi sadece yaş tespiti veya sadece cinsiyet tespitine de rastlamak mümkündür. Literatürdeki çalışmalar cinsiyet tespiti, yaş tespiti, yaş ve cinsiyet tespiti ve çözünürlüğe bağlı tespit olarak ayrı ayrı ele alınacaktır. Yüz görüntülerini elde edebilmek için yüz tespitinde en çok Viola Jones Algoritması kullanılmıştır [10]. Viola Jones Algoritması detaylı olarak Bölüm 3'te ele alınacaktır.

2.1 Cinsiyet Tespiti

Yüz görüntülerinden cinsiyet tespiti konusunda ulaşılabilen en eski çalışma 1991'de yapılmıştır. B. A. Golomb ve arkadaşlarının yaptığı çalışmada, 45'i kadınlara, 45'i erkeklere ait olmak üzere 90 adet görüntü kullanılmış, görüntülerden yüz bölümü çıkarılarak 30x30 olarak boyutlandırılmıştır. Yapay Sinir Ağları kullanılarak gerçekleştirilen çalışmada elde edilen ortalama hata oranı %8.1 dir [11].

1996'da S. Tamura ve arkadaşlarının yaptığı çalışmada, insanların görüntüden cinsiyet tespit edebilmesi için görüntünün en az 16x16 boyutunda olması gerekmesine rağmen, Yapay Sinir Ağları kullanılarak 8x6 boyutundaki görüntülerden %90'dan fazla başarımla cinsiyet tespiti yapılabildiği ortaya koyulmuştur [12].

1995'de Corinna Cortes ve Vladimir Vapnik tarafından Destek Vektör Makineleri (DVM) [13] yönteminin ortaya koyulmasıyla Yapay Sinir Ağları yönteminin yerini yavaş yavaş DVM'e bıraktığı gözlemlenmiştir [14] [15] [16].

2007'de Shumeet Baluja ve Henry Rowley tarafından yapılan çalışmada, düşük çözünürlüklü gri seviyeli görüntüler üzerinde sadece 10 piksel karşılaştırması yapılarak %80 başarı, 50 piksel karşılaştırması yapılarak %90 başarı elde edilmiştir. Sınıflandırıcı olarak AdaBoost ve DVM tabanlı sınıflandırıcılar kullanılmıştır [14].

2008'de E. Ma'kinen ve R. Raisamo tarafından yapılan çalışmada, görüntülerdeki yüzlerin otomatik tespit edilmesinden sonra otomatik olarak hizalanmasının cinsiyet

tespitindeki başarıma katkısı olmadığı fakat manuel yapılan hizalama işleminin başarıyı biraz iyileştirdiği gözlemlenmiştir. Farklı görüntü boyutları için aynı oranlarda başarı elde edilmiştir. En başarılı sınıflandırma sonucunu DVM vermesine rağmen Adaboost ve Yapay Sinir Ağları sınıflandırma yöntemlerinin de DVM başarıma yakın sonuçlar verdiği ortaya koyulmuştur [15].

2010'da S. Ravi ve S. Wilson tarafından yapılan çalışmada, RGB görüntüler YCbCr renk uzayına dönüştürülerek ten rengi olan bölge tespit edilmiştir. Tespit edilen bölgeden sırasıyla ağız, göz, burun bölgesinin yeri tespit edilerek elde edilen veriler DVM ile sınıflandırılmıştır [16].

2012'de V. Khryashchev ve arkadaşları tarafından yapılan çalışmada, görüntülerden adaptif öznelikler çıkartılarak elde edilen öznelikler DVM ile sınıflandırılarak %79.6 başarı elde edilmiştir. Elde edilen başarı, eğitim kümesinin her bir sınıf için 5000 görüntü içermesi durumunda %91'e çıkmaktadır. [17].

2013'de Emon Kumar Dey ve arkadaşları tarafından yapılan çalışmada, yüz görüntülerinden öncelikle yüz bölgesi tespit edilerek görüntüden çıkarılmış, önceki çalışmalarda kullanılan Yapay Sinir Ağları ve DVM'den farklı olarak Yerel İkili Örüntü operatörü kullanılmış ve ardından Ayrık Kosinüs Dönüşümü'nden (DCT) faydalanılmıştır. Elde edilen sonuçlar Manhattan uzaklık hesaplamasıyla uzaklığa bağlı bir sınıflandırıcı yardımıyla sınıflandırılarak %78'in üzerinde başarı elde edilmiştir [18].

2.2 Yaş Tespiti

Yaş tespiti cinsiyet tespitine nazaran çok daha karmaşık bir problem olduğundan, yaş tespiti ile ilgili çalışmalar yakın tarihte başlamış ve yaygınlaşmıştır. Yaşı belirleyen keskin kriterler olmaması ve yaşlanma sürecinin kişiden kişiye farklılık göstermesi gibi sebeplerden dolayı yaş tespiti güncelliğini koruyan bir problemdir. Bu alanda ulaşılabilen ilk çalışma 2007 yılında yapılmıştır. X. Geng ve arkadaşları tarafından yapılan çalışmada kişinin kronolojik sıradaki görüntüleri kullanılarak temsili bir alt uzay yardımıyla yaşlanma örüntüsü (Aging Pattern Subspace) elde edilmiştir. Elde edilen yaşlanma örüntüsü önceden görülmemiş yüz görüntüsü üzerine uygulanarak görüntü yeniden oluşturulmuş ve görüntüden yaş tespiti yapılmıştır. Yaşlanma örüntüsü algoritmasının diğer algoritmalara göre ciddi bir başarı üstünlüğü

sağlamadığı fakat elde edilen sonuçların insanlar tarafından yapılan yaş tespitiyle kıyaslanabilir durumda olduğu gözlemlenmiştir [19].

2009 yılında J. D. Tzia ve C. L. Huang tarafından yapılan ve Aktif Görünüş Modeli (Active Appearance Model) [20] kullanılarak yaş özniteliklerinin elde edildiği çalışma, yüz tespiti, yüz öznitelikleri içeren bölgelerin aranması, yaş özniteliklerinin bulunması ve yaş tahmini olmak üzere 4 modülden oluşmaktadır. 200x240 boyutlarında portre görüntüleri kullanılarak yaklaşık %73 başarımla elde edilmiştir [21].

2011'de S. E. Choi ve arkadaşları tarafından yapılan bir çalışmada, hiyerarşik sınıflandırma metodu kullanılmış, yerel ve global öznitelikler bir arada kullanılarak hibrit bir yöntem geliştirilmiştir. Gabor filtreleri kullanılarak kırışıklık, YİÖ yöntemiyle ise cilt özneliği elde edilmiştir. Elde edilen öznitelikler DVM ve Destek Vektör Regresyon yöntemi ile birleştirilerek sınıflandırılmış ve yaş tespiti yapılmıştır. Elde edilen başarımla, BERC, PAL ve FG-NET veri tabanları kullanılarak yapılan diğer çalışmaların başarımlarından daha yüksek olduğu gözlemlenmiştir [22].

2012'de G. Guo ve X. Wang tarafından yapılan bir çalışmada, yaş tespitinin görüntüdeki kişinin yüz ifadesinden etkilenip etkinlenmediği incelenmiş ve farklı yüz ifadelerine sahip görüntülerde başarımla yüksek bir yaş tespiti için geliştirilebilecek metotlar ele alınmıştır [23].

2013'te H. Han ve arkadaşları tarafından yapılan bir çalışmada, FG-NET, MORPH Album2, ve PCSO veri tabanları kullanılarak yapılan araştırmalar sonucu yaş tespitinde gözlerin ve burnun diğer yüz bileşenlerine göre daha çok bilgi içerdiği gözlemlenmiştir. Ayrıca insan algısının kitle kaynak aracılığıyla yaş tespitini nasıl yaptığı incelenmiştir [24].

2014'te Ji-Xiang Du ve arkadaşları tarafından yapılan çalışmada, görüntü küçük parçalara ayrılmış daha sonra Super-Resolution Reconstruction algoritması ile yüksek çözünürlüklü görüntüler elde edilmiştir. Elde edilen yüksek çözünürlüklü görüntüler Yapay Sinir Ağları ile sınıflandırılarak ,yaş bilgisi tahmin edilmiştir [25].

2.3 Yaş ve Cinsiyet Tespiti

Literatürde yaş ve cinsiyet tespitini bir arada yapan çok fazla çalışmaya rastlanmamaktadır. 2002'de J. Hayashi ve arkadaşları tarafından yapılan çalışmada, yüzdeki kırışıklıklar ve yüzün rengi kullanılmıştır. Yüzde bulunan kırışıklıklar, yüzdeki bölgelerin şekli ve boyutu modelleme için seçilmiştir. Ayrıca yüz görüntüleri ve anahtar kelimeler arasında bağ kurmak için gizli anlamsal indeksleme kullanılarak bir metot önerilmiştir [26].

2003 yılında R. Iga ve arkadaşları tarafından yapılan çalışmada, ten rengi kullanılarak yüz bölgesi olmaya aday bölgeleri elde etmeye yarayan bir algoritma geliştirilmiş ve yüz bölgesinden elde edilen öznelikler DVM kullanılarak sınıflandırılmıştır. Sistem, 150'si kadın, 150'si erkek olmak üzere 15-64 yaş aralığındaki kişilerin bulunduğu 300 görüntülük bir veri tabanı ile test edilerek, cinsiyet için %97.3, yaş için ise %67.4 başarımla elde edilmiştir [27].

2010 yılında Hironobu Fukai ve arkadaşları tarafından yapılan çalışmada, insandaki yaş algısının yüzdeki hangi özneliklere göre şekillendiği göz önünde bulundurularak, bu doğrultuda yüzdeki renkli noktalar, kırışıklıklar, sarkmalar, yüzün şekli ve rengi öznelik olarak kullanılmış ve elde edilen öznelikler Yapay Sinir Ağları kullanılarak sınıflandırılmıştır. Farklı öznelikler kullanılarak yapılan testlerde cinsiyet için %84 ila %94, yaş için ise 4 yaş ila 12 yaş yaklaşık başarımla elde edilmiştir [28]

2.4 Çözünürlüğe Bağlı Tespit

Literatürdeki çözünürlüğe bağlı tespit yapan çalışmalar incelendiğinde, çalışmaların tamamının cinsiyet tespiti yaptığı, yaş tespitinin çözünürlüğe bağlı başarımlarının incelenmediği görülmüştür. 2002'de B. Moghaddam ve M. Yang tarafından yapılan bir çalışmada, FERET veri tabanı kullanılarak 8 farklı sınıflandırıcının 21x12 ve 84x48 boyutlarındaki görüntülerde cinsiyet tespiti başarımları incelenmiş, iki çözünürlük arasındaki başarımların farkının %1 olduğu gözlemlenmiş ve en iyi performansın DVM'de elde edildiği tespit edilmiştir [29].

2013'te Y. S. El-Din ve arkadaşları tarafından yapılan bir çalışmada FERET veri tabanı kullanılarak 16x16 boyutundaki görüntülerden DVM ile cinsiyet tespiti yapılmış ve %95 başarımlar elde edilmiştir [30].

2014 yılında Yasmina Andreu ve arkadaşları tarafından yapılan bir çalışmada, 2x1, 3x2, 6x5, 8x6, 11x9, 16x13, 22x18, 45x36, 90x72, 329x264 olmak üzere on farklı çözünürlükte cinsiyet tespiti gerçekleştirilmiş ve sonuçlar karşılaştırılmıştır. Sınıflandırıcı olarak EYK ve DVM kullanılmıştır [9]. On farklı çözünürlük kullanılması ve düşük çözünürlüklerde bile yaklaşık %80 başarımlar elde edilmesi bu tez çalışmasına temel oluşturmuştur yeni sınıflandırıcılar ve öznelik seçimleri denenerek yaş için de kabul edilebilir başarımlar elde edilmesi hedeflenmiştir





3. KULLANILAN ARAÇ, VERİ TABANI VE YÖNTEMLER

Tez çalışmasında faydalanılan araç, veri tabanı ve yöntemler bu bölümde detaylı olarak ele alınmıştır.

3.1 MORPH Veri Tabanı

2006 yılında yayımlanan MORPH [31] veri tabanı halka açık en büyük veri tabanı olma özelliğine sahip olup, dünyada 30'dan fazla ülkede aktif olarak kullanılmaktadır. Veri tabanı farklı yaş, cinsiyet ve etnik kökene ait kişilerin portre görüntülerini içermektedir. MORPH veri tabanı Album 1 ve Album 2 olmak üzere iki farklı albümden oluşmaktadır.

Album 1, 26 Ekim 1962 ve 7 Nisan 1998 tarihleri arasında çekilmiş 515 adet görüntü içermektedir. Aynı kişiye ait görüntülerin kaydedilmesi arasındaki zaman 46 günden 29 yıla kadar farklılık göstermektedir ve herkesin erişimine ve kullanımına açıktır.

Album 2, hala gelişmekte olup her üç ayda bir yeni görüntüler eklenmektedir. Akademik araştırmacılara Album 2'nin daha daraltılmış versiyonuna erişim izni verilmiştir. Bu versiyonda 16 - 76 yaş aralığındaki 13000 farklı kişiye ait toplamda 55134 adet görüntü bulunmakta olup bu görüntülerin %15'i kadınlara, %85'i erkeklere aittir. Bu tez çalışmasında Album 2'nin daraltılmış versiyonu kullanılmıştır.

Resim 3.1'de MORPH veri tabanındaki görüntülerden örnekler gösterilmiştir. Veri tabanındaki görüntüler ortak bir çözünürlüğe sahip değildir. Yüksek ve düşük çözünürlüklü görüntüler bir arada bulunmaktadır.



Resim 3.1: MORPH Veri tabanından görüntü örnekleri.

Veri tabanı aynı kişiye ait farklı zamanlarda çekilmiş ortalama dört görüntü içermektedir. Aynı kişiye ait farklı zamanlarda çekilmiş görüntü örnekleri Resim 3.2’de gösterilmiştir.



Resim 3.2: Soldan sağa, eskiden yeniye aynı kişilere ait farklı zamanda çekilmiş görüntüler.

Bu görüntüler kontrolsüz bir ortamda kaydedilmiş olup görüntülerde aydınlanma, yüz ifadesi, kafa pozisyonu, bakışların yönü farklılık göstermektedir. Bu farklılıklardan birkaç örnek Resim 3.3’te gösterilmiştir.



Resim 3.3: Farklı aydınlanma, yüz ifadesi, kafa pozisyonu, bakış yönü örnekleri.


3.2 FG-NET Yaşlanma Veri Tabanı

FG-NET yaşlanma veri tabanı FG-NET (Face and Gesture Recognition Network) projesinin bir parçası olarak 2004 yılında yayınlanmıştır. Veri tabanı 0 – 69 yaş arası 82 farklı kişiye ait 1002 adet yüz görüntüsü içermektedir. Veri tabanının isminden de anlaşılacağı gibi görüntü isimlerinden yalnızca yaş bilgisi elde edilebilmektedir. Veri tabanında renkli görüntülerin yanı sıra siyah beyaz görüntüler de yer almaktadır. Resim 3.4’te veri tabanından görüntü örnekleri verilmiştir.




Resim 3.4: FG-NET yaşlanma veri tabanından görüntü örnekleri.

Veri tabanında aynı kişiye ait farklı zamanlarda çekilmiş ortalama 12 adet görüntü bulunmaktadır. Resim 3.5 ve Resim 3.6'da aynı kişinin farklı yaşlarında çekilmiş görüntülere yer verilmiştir.



Resim 3.5: Soldan sağa, yukarıdan aşağıya, eskiden yeniye aynı erkeğin 2 - 43 yaş arası görüntüleri.



Resim 3.6: Soldan sađa, yukarıdan ařađıya, eskiden yeniye aynı kadının 3 – 41 yař arası grntleri.

Veri tabanındaki grntler kontrolsz bir ortamda kaydedilmiř olup grntlerde aydınlanma, yz ifadesi, kafa pozisyonu, bakıřların yn farklılık gstermektedir. Bu farklılıklardan birkaç rnek Resim 3.7’de gsterilmiřtir.



Resim 3.7: Farklı aydınlanma, yüz ifadesi, kafa pozisyonu, bakış yönü örnekleri.

MORPH ve FG-NET veri tabanları içerdiği görüntü sayısı ve görüntülerin yapısı olarak birbirinden oldukça farklıdır. MORPH veri tabanındaki görüntü sayısı 55134 iken, FG-NET veri tabanındaki görüntü sayısı 1002 dir. MORPH veri tabanı 16-76

yaş aralığındaki kişilere ait görüntüler içerirken, FG-NET veri tabanında bu aralık 0-79 dur. MORPH veri tabanı görüntülerdeki kişilere ait yaş ve cinsiyet bilgilerini bir arada barındırırken, FG-NET veri tabanı kişilerin sadece yaş bilgisini içermektedir. MORPH veri tabanında aynı kişiye ait farklı zamanlarda çekilmiş ortalama dört adet görüntü bulunurken, FG-NET veri tabanında bu rakam ortalama onikiye yükselmektedir. MORPH veri tabanında siyahilere ait görüntüler de bulunurken, FG-NET veri tabanında siyahilere ait görüntü bulunmamaktadır. MORPH veri tabanındaki görüntülerin arka planı genelde sabit renklerden oluşurken, FG-NET veri tabanındaki görüntülerin arka planı farklı ve karışık renklerden oluşmaktadır. MORPH veri tabanındaki görüntülerdeki kişiler daha ciddi pozlar verirken, FG-NET veri tabanındaki görüntülerdeki kişiler genelde gülümseyerek poz vermişlerdir.

3.3 K-En Yakın Komşu Algoritması (K-EYK)

K-En Yakın Komşu algoritması sınıflandırmada kullanılan bir algoritmadır. K-EYK sınıflandırıcısının kullanım alanlarından bazıları veri madenciliği, örüntü tanıma, görüntü işleme ve metin tanımadır. Sınıflandırılmak istenen veri daha önceden sınıflandırılmış olan kendisine en yakın K adet verinin dahil olduğu sınıfa ait olacak şekilde sınıflandırılır. En yakın K adet veri farklı sınıfların elemanlarından oluşuyorsa yeni veri, çoğunluğun ait olduğu sınıfa dahil edilir. Sınıflandırma yaparken önceki sınıflandırma sonuçlarına ihtiyaç duyduğu için K-EYK ile sınıflandırma gözetimli (supervised) öğrenme metodudur. En yakın verilerin bulunması için üç farklı mesafe hesaplama metodu bulunmaktadır.

- **Öklid Mesafesi:** İki nokta arasındaki doğrusal mesafedir. En yaygın kullanılan mesafe hesaplama tekniğidir. Bu tez çalışmasında kullanılan mesafeler Öklid mesafesidir. Öklid mesafesinin hesaplanması için gerekli formül Eşitlik (3.1)'de verilmiştir.

$$d = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (3.1)$$


- **Manhattan Mesafesi:** Koordinat düzleminde olduğu gibi iki nokta arasındaki yolun birimlerden oluşması durumunda kullanılan mesafe hesaplama tekniğidir. Manhattan mesafesinin hesaplanması için gerekli formül Eşitlik (3.2) 'de verilmiştir.

$$d = \sum_{i=1}^k |x_i - y_i| \quad (3.2)$$

- **Minkowski Mesafesi:** Öklid ve Manhattan mesafesinin genelleştirilmiş halidir. $p=1$ değeri için Manhattan, $p=2$ değeri için Öklid mesafesi hesaplanmaktadır. Minkowski mesafesinin hesaplanması için gerekli formül Eşitlik (3.3) 'te verilmiştir.

$$d = \left(\sum_{i=1}^k (|x_i - y_i|)^p \right)^{\frac{1}{p}} \quad (3.3)$$

Eşitlik (3.1), (3.2) ve (3.3) 'te d mesafeyi, k aralarındaki mesafe hesaplanacak olan toplam nokta sayısını, x_i ve y_i ise aralarındaki mesafe hesaplanacak noktaları ifade etmektedir. $K=3$ için K-EYK algoritması ile sınıflandırma adımları Şekil 3.1'de gösterilmiştir.



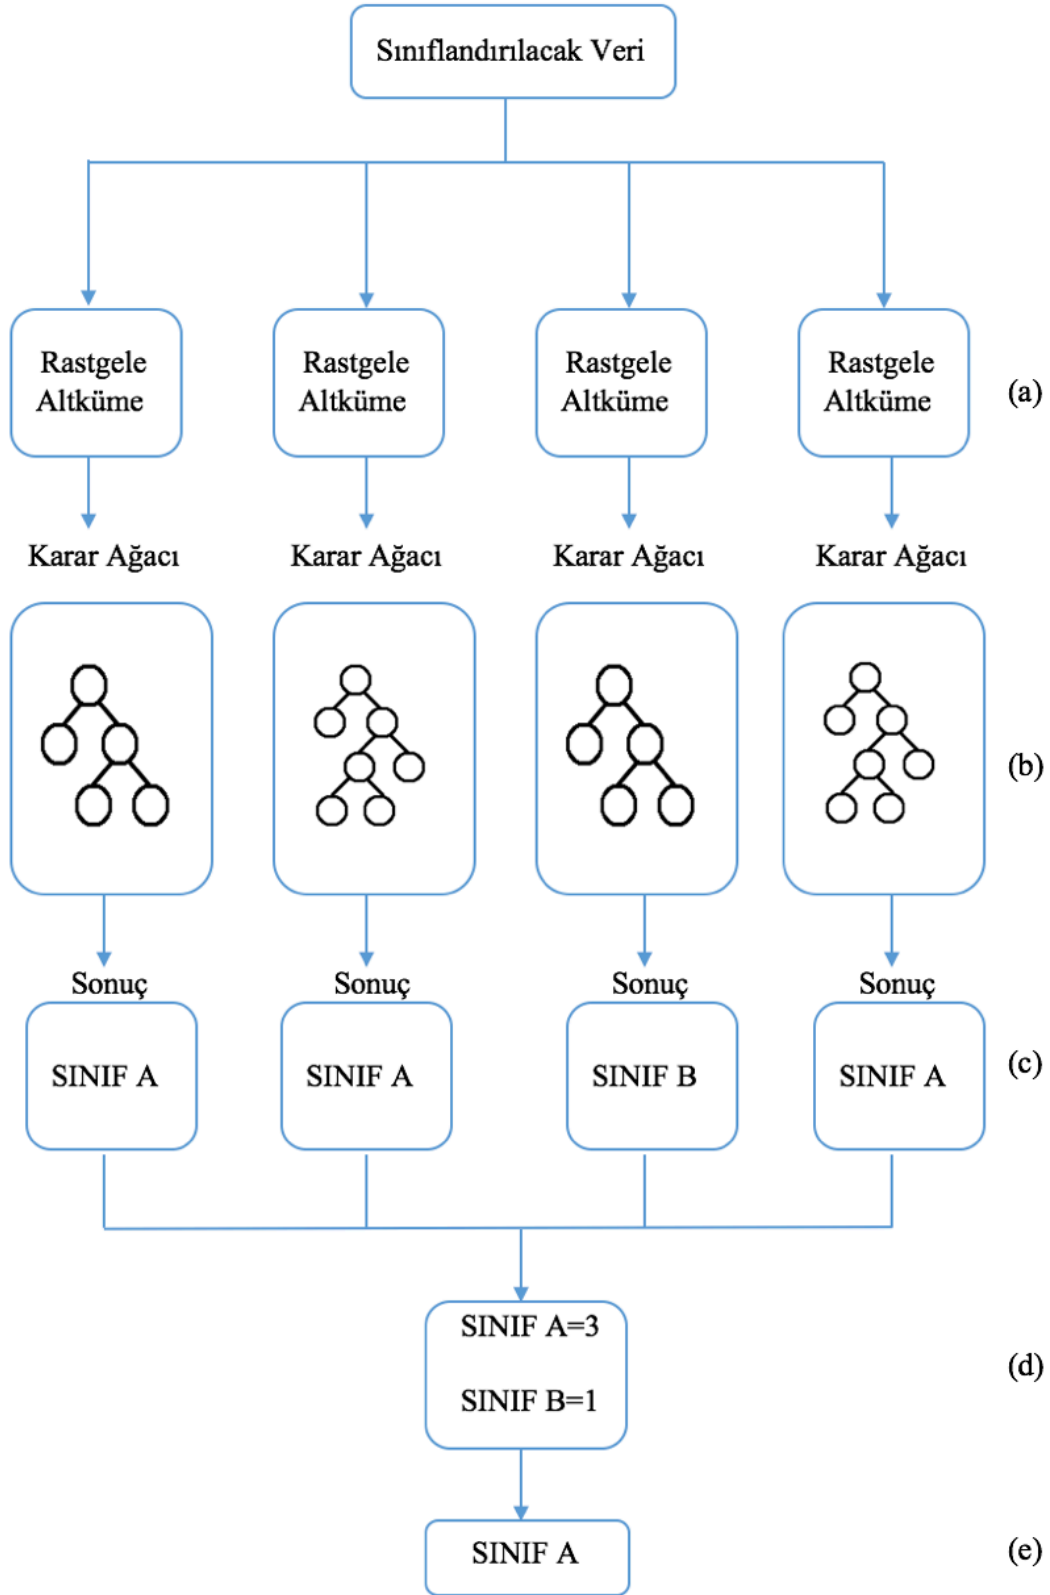
Şekil 3.1: (a) Mavi ve turuncu olmak üzere iki farklı sınıfın bulunduğu sisteme, sınıflandırılacak olan siyah yıldızın dahil edilmesi. (b) Sınıflandırılacak olan siyah yıldızın en yakın üç adet yıldızın Öklid mesafesi ile bulunması. (c) Siyah yıldızın en yakın üç yıldızdan iki yıldızın turuncu, bir yıldızın mavi olması sebebiyle, çoğunluk turuncu sınıfa ait olduğundan, siyah yıldızın turuncu olarak sınıflandırılması.

K adet en yakın öznitelik Öklid mesafesi kullanılarak hesaplanır. En yakın üç öznitelikten ikisi turuncu sınıfa ait olduğu için yeni gelen öznitelik de turuncu sınıfa ait olacak şekilde sınıflandırılır.

K-EYK sınıflandırmasının avantajları büyük eğitim kümelerinde etkili olması ve gürültülü verileri tolere edebilmesidir. Dezavantajları ise K değerinin belirli olmayışı ve kullanıcı tarafından belirlenmesi gerekmesi, mesafe hesaplamada kullanılacak yöntemde bir kesinlik olmaması ve yeni her bir veri için diğer tüm verilere olan uzaklık tek tek hesaplandığı için çok yüksek hesaplama maliyetinin olmasıdır.

3.4 Rastgele Orman (RO)


Rastgele Orman [33] sınıflandırıcısı çok sayıda karar ağacı (decision trees) kullanmaktadır. Sınıflandırılacak veriler rastgele olarak seçilir ve seçilen veriler ile karar ağaçları oluşturulur. Tek bir karar ağacı yüksek varyans ve yüksek meyil (bias) içerebilir. Rastgele Orman algoritması çok sayıda karar ağacı kullanarak yüksek varyans ve yüksek meyilli dengeler. Her bir karar ağacı mümkün olan en büyük içeriğe kadar genişleyebilir ve karar ağaçlarında budama söz konusu değildir. Karar ağaçlarından elde edilen sonuçlar oylanarak veri en çok oyu alan sınıfın elemanı olacak şekilde sınıflandırılır. Şekil 3.2’de Rastgele Orman sınıflandırıcısının işlem adımları gösterilmiştir. RO’nun avantajları çok yüksek sayıda veriyi hızlı bir şekilde sınıflandırabilmesi, eksik veriler için öngörüle bulunabilmesi, yüksek başarımla çalışmasıdır. Dezavantajı ise gürültülü verilere yeterince toleransı olmamasıdır.



Şekil 3.2: (a) Sınıflandırılacak verinin rastgele alt kümelere ayrılması. (b) Alt kümelerin her birinden karar ağacı oluşturulması. (c) Verinin her bir karar ağacına göre sınıflandırılması. (d) Karar ağaçlarından çıkan sonuçların oylama yöntemiyle toplanması. (e) Verinin en çok oyu alan sınıfa dahil edilmesi.

3.5 Yerel İkili Örüntüler (Local Binary Patterns)

Yerel İkili Örüntüler (YİÖ) yönteminde piksellerin komşulukları kullanılmaktadır. Merkez ve komşu piksel değerleri arasında sıralı ikili kıyaslamalara dayanılarak merkez piksel etiketlenmektedir. YİÖ’de hesaplamalar gri seviyeli görüntüler üzerinde yapılmaktadır. YİÖ örüntü ve yüz tanıma uygulamalarında sıkça kullanılan oldukça etkili bir yöntemdir. Pikseller komşularıyla birlikte değerlendirildiğinden YİÖ aydınlanmadaki değişimlere karşı dayanıklıdır. Resim 3.8’de farklı aydınlanma koşullarındaki görüntülerin YİÖ sonucu gösterilmiştir.



Resim 3.8: Farklı aydınlanma koşullarındaki görüntüler ve her bir görüntünün YİÖ sonucu.

Yerel İkili Örüntüler’in farklı çeşitleri mevcuttur. Bunlardan en çok kullanılanları aşağıda incelenecektir.

3.5.1 Orijinal yerel ikili örüntüler (YİÖ)


Pikselin değeri, pikselin 3x3 komşuluğunda bulunan piksellerin değerleriyle karşılaştırılarak elde edilen ikili tabandaki sayının onlu tabandaki karşılığı olarak belirlenir. Eşitlik (3.4) ’te matematiksel olarak ifade edilmiştir.

$$LBP(x_c, y_c) = \sum_{n=0}^7 s(i_n - i_c)2^n \quad (3.4)$$

Eşitlik (3.4) 'te; i_c merkez pikselin parlaklık değerini, (x_c, y_c) ise merkez pikselin koordinatlarını, i_n ise merkez pikseli çevreleyen 3x3 komşuluktaki piksellerin parlaklık değerini ifade etmektedir. $s(x)$ fonksiyonun tanımı Eşitlik (3.5)'te verilmiştir.

$$s(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (3.5)$$

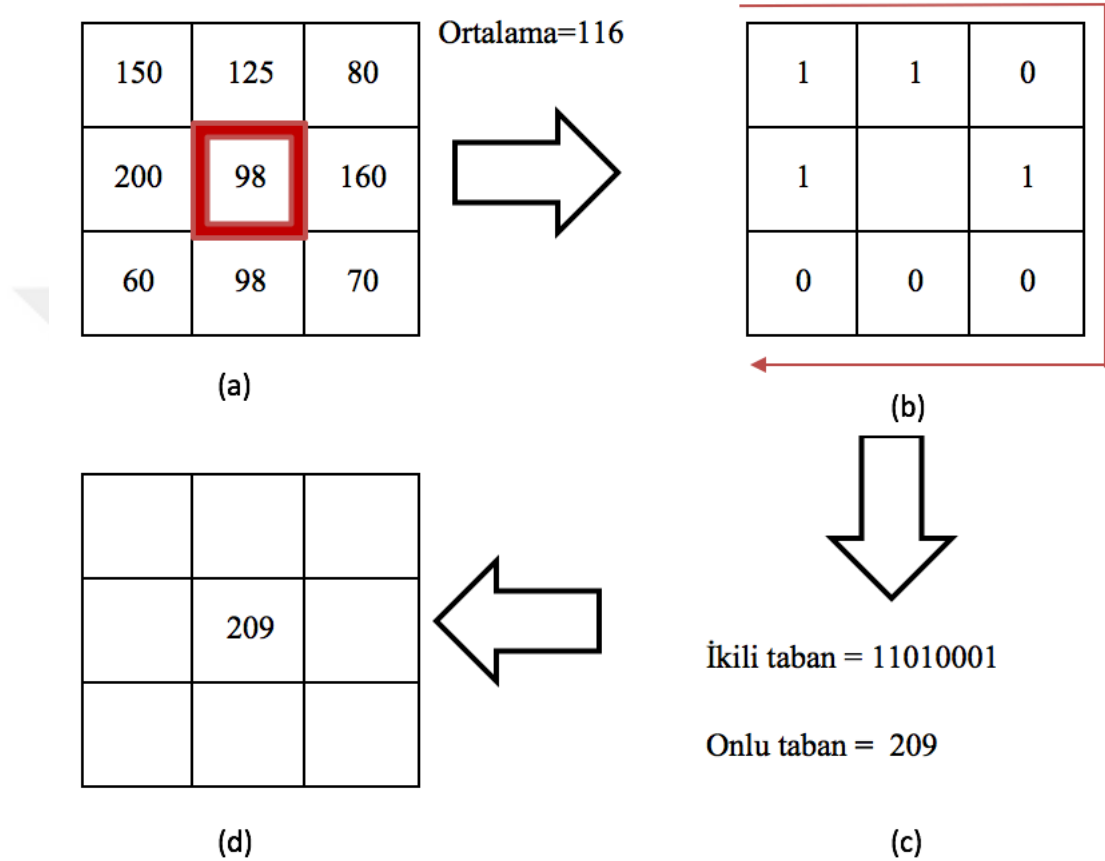
Orijinal YİÖ için örnek bir hesaplama Şekil 3.3'te gösterilmiştir.



Şekil 3.3: (a)YİÖ değeri hesaplanacak pikselin sekiz komşuluğundaki piksellerle birlikte alınması. (b) Sekiz komşuluktaki piksellerin değerlerinin merkez piksel değeriyle kıyaslanarak 1 veya 0 değeri alması. (c) Sol üst köşedeki komşu pikselden başlanarak 1 ve 0 değerlerinin yanyana yazılması ve ikili tabandan onlu tabana dönüşüm yapılması. (d) Merkezdeki pikselin yeni değerinin belirlenmesi.

3.5.2 Değiştirilmiş yerel ikili örüntüler (modified local binary patterns)

Orijinal Yerel İkili Örüntüler'den farklı olarak komşu pikseller merkez piksel yerine, 9 pikselin ortalaması olan değerle karşılaştırılmaktadır. Şekil 3.4'te hesaplama bir örnek üzerinde gösterilmiştir.

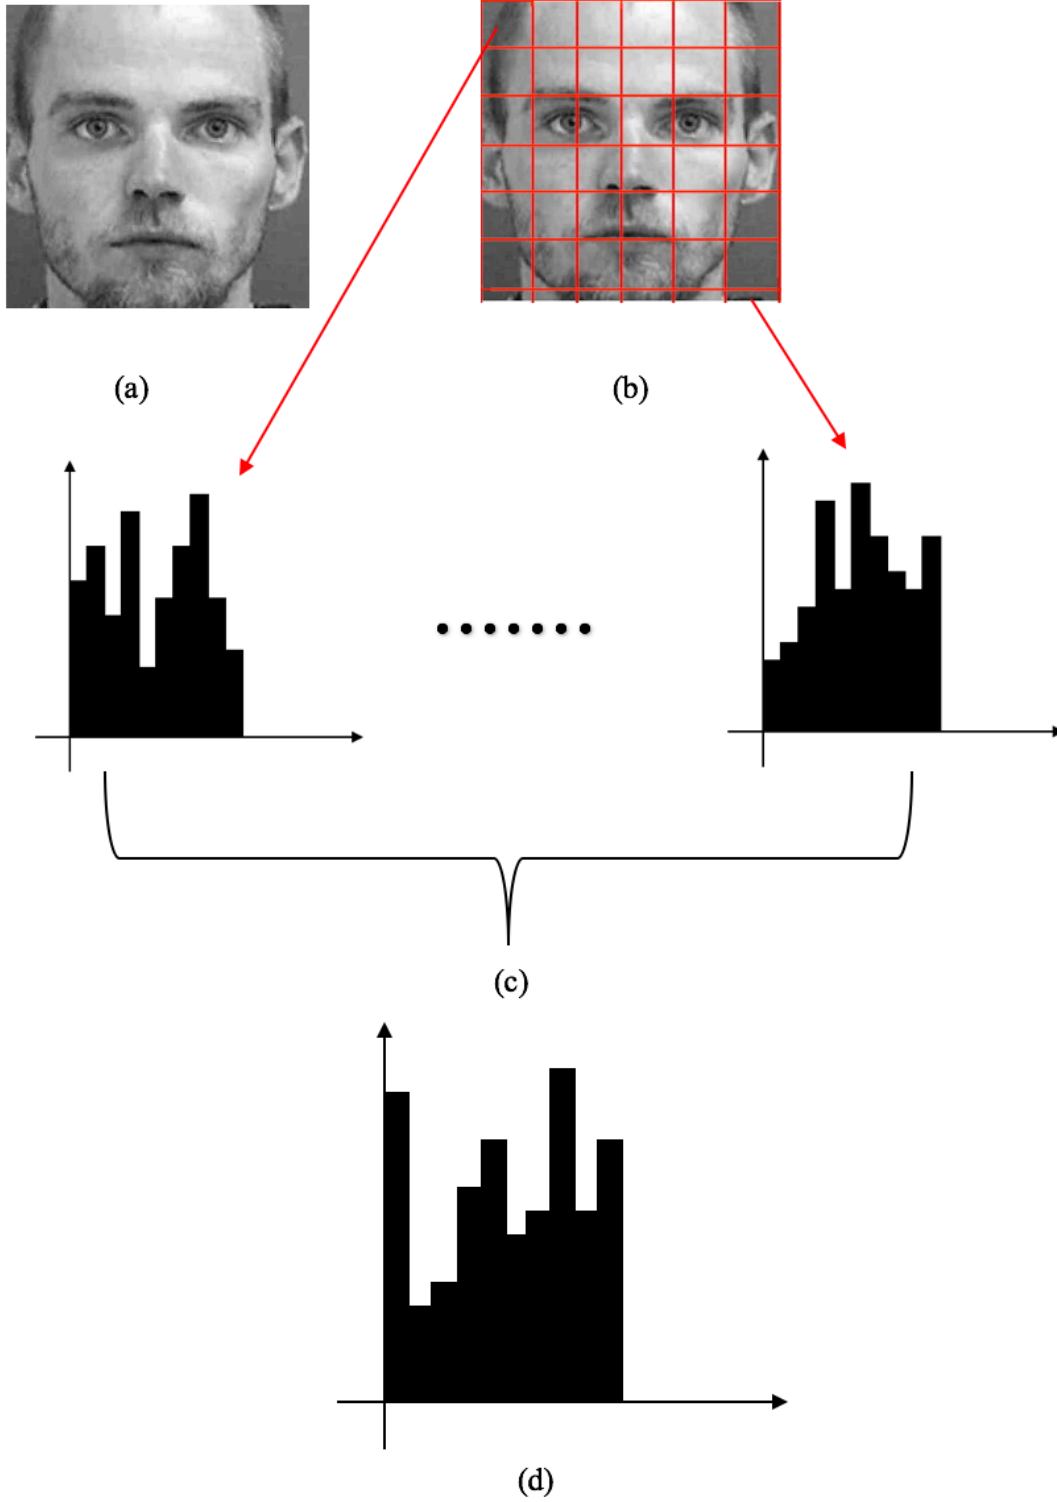


Şekil 3.4: (a)YİÖ değeri hesaplanacak pikselin sekiz komşuluğundaki piksellerle birlikte alınması ve sekiz komşuluktaki piksel değerlerinin ortalamasının hesaplanması. (b) Sekiz komşuluktaki piksellerin değerlerinin ortalamayla kıyaslanarak 1 veya 0 değeri alması. (c) Sol üst köşedeki komşu pikselden başlanarak 1 ve 0 değerlerinin yanyana yazılması ve ikili tabandan onlu tabana dönüşüm yapılması. (d) Merkezdeki pikselin yeni değerinin belirlenmesi.

3.5.3 Çok bloklü yerel ikili Örüntüler (multi block local binary patterns)

Görüntü bloklara bölünerek YİÖ hesaplaması yapılır. İkili tabanda elde edilen değerlerde 0'dan 1'e, 1'den 0'a olan geçiş sayıları hesaplanır. Örneğin, 11010001 ikili sayısında üç adet geçiş, 11110000 ikili sayısında bir adet geçiş bulunmaktadır. En fazla ikiye kadar fazla geçiş olan durumlar histogramda ayrı ayrı temsil edilirken, ikiden fazla geçiş içeren durumlar histogramda birlikte temsil edilir. Alt parçaların


her birisi için histogram oluşturulduktan sonra tüm histogramlar tek bir histogramda birleştirilir. Şekil 3.5'te Çok Bloklü Yerel İkili Örüntüler hesaplamasındaki adımlar gösterilmiştir.



Şekil 3.5: (a) Gri seviyeli görüntü. (b) Gri seviyeli görüntünün küçük parçalara bölünmesi. (c) Her bir küçük parça için histogram oluşturulması. (d) Elde edilen tüm histogramların tek bir histogramda toplanması.

3.6 Gradyan Yönleri Histogramları (Histogram of Oriented Gradients)

Gradyan Yönleri Histogramları (HoG), bilgisayarla görü ve görüntü işlemede sık sık kullanılan bir öznitelik temsil yöntemidir. HoG yönteminde görüntü, hücre (cell) adı verilen birbiriyle bağlantılı küçük parçalara bölünür. Hücreleri içine alacak ve üst üste gelecek şekilde bloklar oluşturulur. Her bir blok için gradyan yönelimi hesaplanarak gradyanların açı değerlerinin dağılımları histogram olarak temsil edilir. Elde edilen histogramlar normalize edildikten sonra tek bir histogramda birleştirilir ve elde edilen histogram öznitelik olarak kullanılır. Gradyan hesaplaması için en çok $[-1, 0, +1]$ maskesi kullanılmaktadır. HoG hesaplamaları lokal olarak yapıldığından geometrik ve fotometrik değişimlere karşı dayanıklıdır. Şekil 3.6'da HoG işlem adımları gösterilmektedir.



Şekil 3.6: (a) Gri seviyeli görüntünün önce hücelere, daha sonra hücrelerden oluşan bloklara bölünmesi, blokların %50 üst üste gelecek şekilde ayarlanması. (b) Elde edilen her bir blok için gradyanların hesaplanması. (c) Her bir blok için gradyanların histogram ile temsil edilmesi. (d) Tüm histogramların arka arkaya eklenmesiyle tek bir histogram elde edilmesi.

3.7 Viola – Jones Yüz Tespit Algoritması

Viola – Jones özellikle yüz tespitinde kullanılan çok başarılı bir yöntemdir. Yöntem temelde dört bileşenden oluşmaktadır. Bunlar aşağıdaki gibidir.

- **Haar - Benzeri Öznitelikler:** Haar – benzeri özniteliklerle görüntü üzerindeki dikdörtgensel bölgelere denk gelen piksel parlaklık değerlerinin toplamının farkı olarak ifade edilebilir. Haar – benzeri öznitelikler Şekil 3.7’de gösterilmiştir.



Şekil 3.7: Haar – benzeri öznitelikler. (a) Üç – dikdörtgen öznitelik.
(b) İki – dikdörtgen öznitelik.


Şekil 3.7’de gösterilen öznitelikler görüntü üzerinde sol üst köşeden başlayarak birer piksel kaydırılarak tüm görüntü taranır. Öznitelikler ile üst üste gelen piksellerin parlaklık değerleri kullanılır. Siyah bölgeye gelen piksellerin parlaklık değerleri toplanır ve beyaz bölgeye gelen piksellerin parlaklık değerlerinin toplamı bu değerden çıkarılır. Buradaki temel mantık yüzde gözlerin olduğu bölgenin yanak ve çene bölgesine göre daha koyu renkte olmasıdır. Yine benzer şekilde gözlerin bulunduğu bölgelerin gözleri ayıran burun bölgesine göre daha koyu olmasıdır. Bu işlem sayesinde yüz olmayan bölgeler büyük ölçüde elenir fakat elde edilen sonuçta gerçek yüz bölgesinin yanı sıra birçok yanlış pozitif sonuçlar da bulunmaktadır. Bunun için diğer aşamalara ihtiyaç duyulmaktadır.

- **İntegral Görüntü:** Dikdörtgen özniteliklerin hesaplanabilmesi için haar – benzeri öznitelik görüntü üzerinde her kaydırıldığında siyah ve beyaz bölgelere denk gelen piksel parlaklık değerlerinin toplanması gerekmektedir.

Hesaplama maliyeti göz önünde bulundurulduğunda bu işlemin maliyeti oldukça yüksektir. Bu maliyetten kurtulmak ve işlemleri hızlandırmak amacıyla integral görüntü yöntemi kullanılmıştır. Bu yöntemde her bir piksel kendisinin solunda ve üstünde kalan piksellerin toplamı olarak yeniden hesaplanır. İntegral görüntüdeki piksel değerleri Eşitlik (3.6)'da verilmiştir.

$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (3.6)$$

Eşitlik (3.6) 'da $ii(x, y)$ integral görüntüyü, $i(x, y)$ ise orijinal görüntüyü ifade etmektedir. İntegral görüntü yöntemi sayesinde haar – benzeri öznelik görüntü üzerinde her kaydırılışında piksel değerlerini tek tek toplamak yerine Şekil 3.7 (a)'daki öznelik sekiz referansla, Şekil 3.7 (b)'deki öznelik ise altı referansla hesaplanabilmektedir. Örnek bir hesaplama Şekil 3.8'de gösterilmiştir.



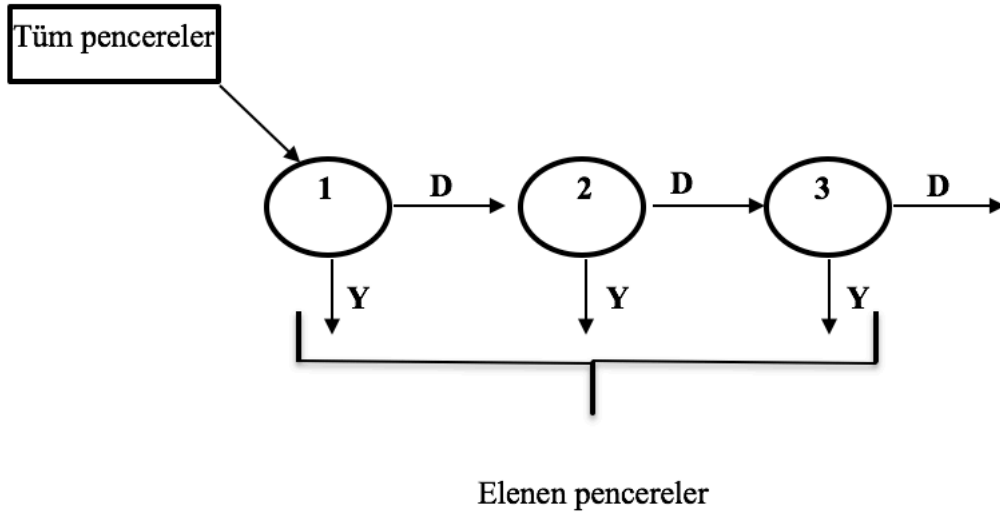
Şekil 3.8: İntegral görüntü hesaplama örneği.

Şekil 3.8'de A dikdörtgeni içindeki piksel değerlerinin toplamı 1 konumundaki pikselin değerine eşittir. 2 konumundaki pikselin değeri A + B'ye , 3 konumundaki pikselin değeri A + C'ye, 4 konumundaki pikselin değeri ise A + B + C + D'ye eşittir. D dikdörtgeninin içindeki piksellerin değerinin toplamı $4 + 1 - (2 + 3)$ olarak hesaplanır.

- **AdaBoost:** AdaBoost bir sınıflandırma algoritmasıdır ve Viola – Jones yönteminde sınıflandırıcıyı eğitmenin yanı sıra özneliklerin elenmesi için

de kullanılmıştır. Dikdörtgen öznitelikler görüntünün farklı boyutlarında da kayan pencereler şeklinde arandığından işlem sonucunda elde çok fazla öznitelik bulunmaktadır. AdaBoost algoritması tarafından zayıf sınıflandırıcıların birleştirilmesiyle esas sınıflandırıcı elde edilir ve esas sınıflandırıcı kullanılarak pencereler arasında yeniden bir eleme gerçekleştirilir.

- **Basamaklı Sınıflandırıcı:** Viola - Jones Algoritması'nın en son adımıdır. Bu adımdaki temel amaç negatif sonuç veren pencerelerin tamamının ve yanlış pozitif sonuç veren pencerelerin elenmesidir. Basamaklı sınıflandırıcıda yüksek tespit oranına sahip sınıflandırıcılar arka arkaya kullanılmakta, her basamakta doğru sonuç vermeyen pencereler elenmekte, böylece son basamağa gelindiğinde tüm basamaklardan elenmeden geçen pencereler elde edilmektedir. Basamaklı sınıflandırıcı yapısı Şekil 3.9'da gösterilmiştir.



Şekil 3.9: Basamaklı sınıflandırıcı yapısı. D harfi doğruyu Y harfi ise yanlış temsil etmektedir. Her adımda yola, sadece doğru sonuç veren pencerelerle devam edilmektedir.


3.8 K - Katlamalı Çapraz Doğrulama (K- Fold Cross Validation)

Makine öğrenme algoritmalarında genel olarak eldeki veriler eğitim ve test kümesi olmak üzere ikiye ayrılır. Makine öğrenme algoritması önce eğitim kümesindeki verileri işleyerek öğrenme işlemini gerçekleştirir, daha sonra öğrendiklerini test kümesindeki veriler üzerinde uygulayarak öngörülerde bulunur. Makine öğrenme algoritmalarının eğitim kümesinde örneğine veya benzerine hiç rastlamadığı bir

duruma test kümesinde rastlaması sonucu doğru öngörüle bulunması beklenemez. Bu yüzden test ve eğitim kümelerinin nasıl seçildiği büyük önem arz etmektedir.

K – Katlamalı Çapraz Doğrulama yönteminde, eldeki veri K adet alt kümeye rastgele bölünür, elde edilen alt kümelerden, K-1 adet alt küme eğitim, geriye kalan 1 adet alt küme ise test kümesi olarak ayarlanır. Eğitim ve test kümesi verileri her seferinde farklı olmak üzere eğitim ve test aşaması toplamda K kez tekrarlanır ve elde edilen başarımlar toplanarak, toplam başarımların K sayısına bölünür. Böylece farklı durumlar için algoritmanın ortalama başarımı elde edilmiş olur. K– Katlı Çapraz Doğrulama yöntemi adımları Şekil 3.10’da gösterilmiştir.

Bu tez çalışmasında yapılan deneylerde 5 – Katlı Çapraz Doğrulama yapılmış ve bu işlem iki kez tekrarlanmıştır.



Şekil 3.10: (a) Eğitim ve test kümelerinin adet ve temsilleri. (b) Her bir iterasyonda eğitim ve test kümelerinin seçilmesi ve her iterasyon sonucunun toplanıp K sayısına bölünerek ortalama başarımın elde edilmesi.

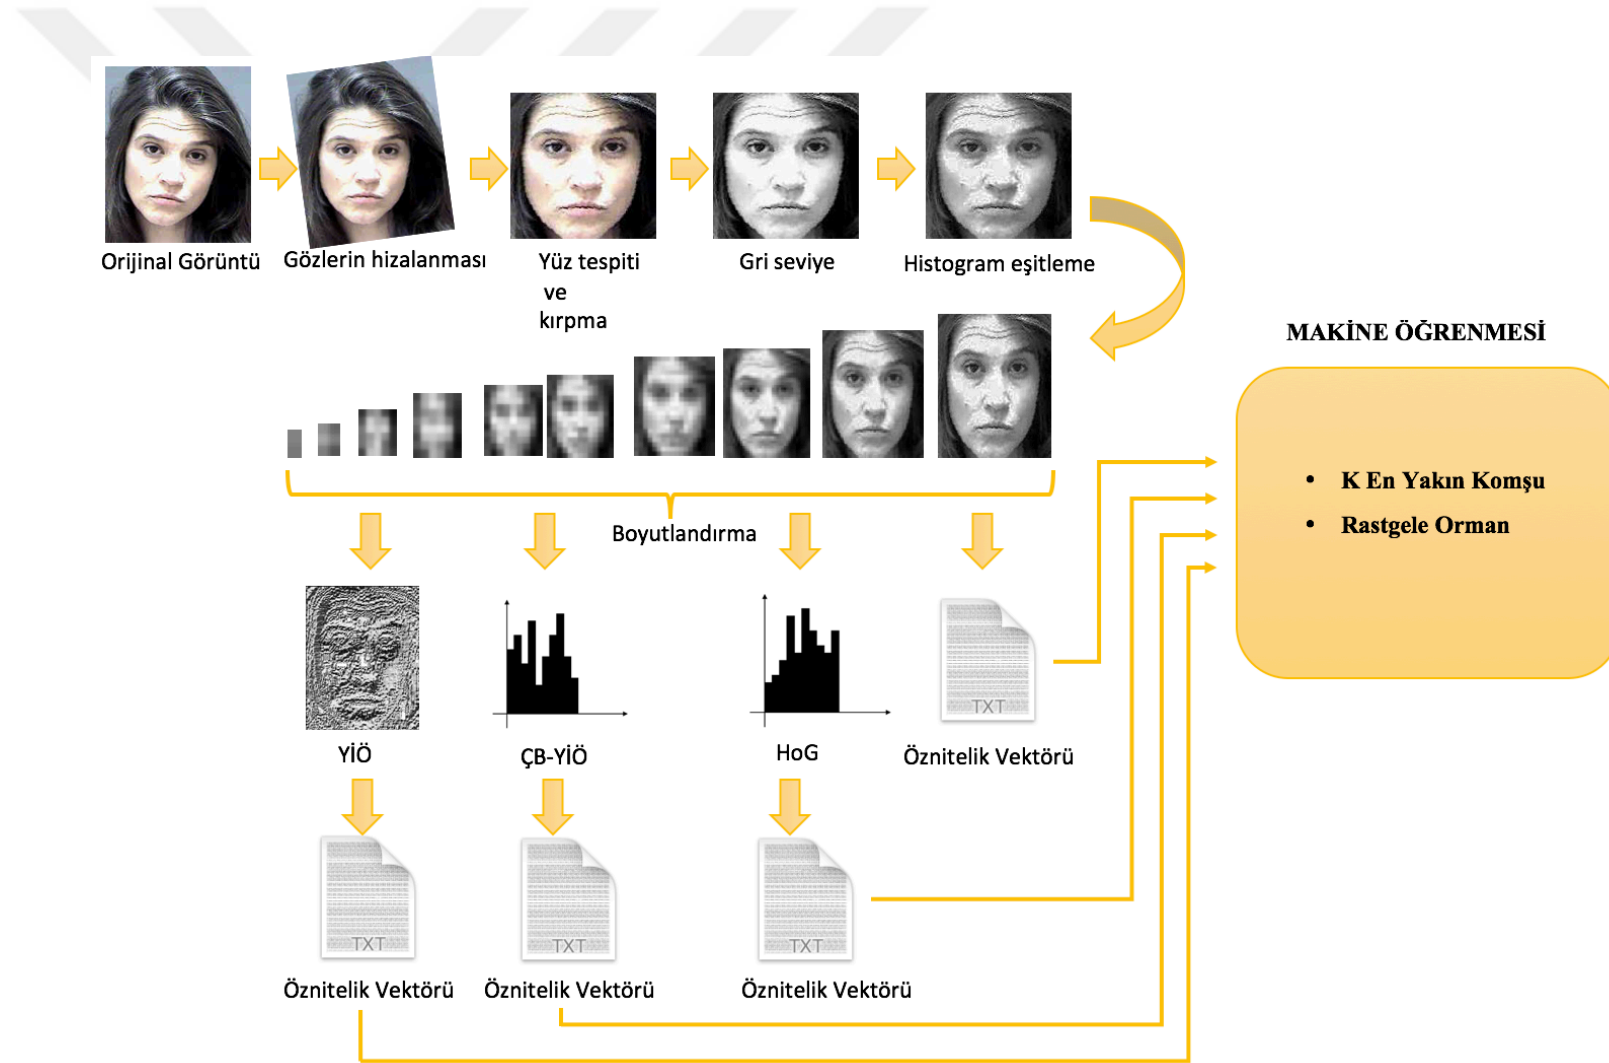


4. DENEYSEL KURULUM

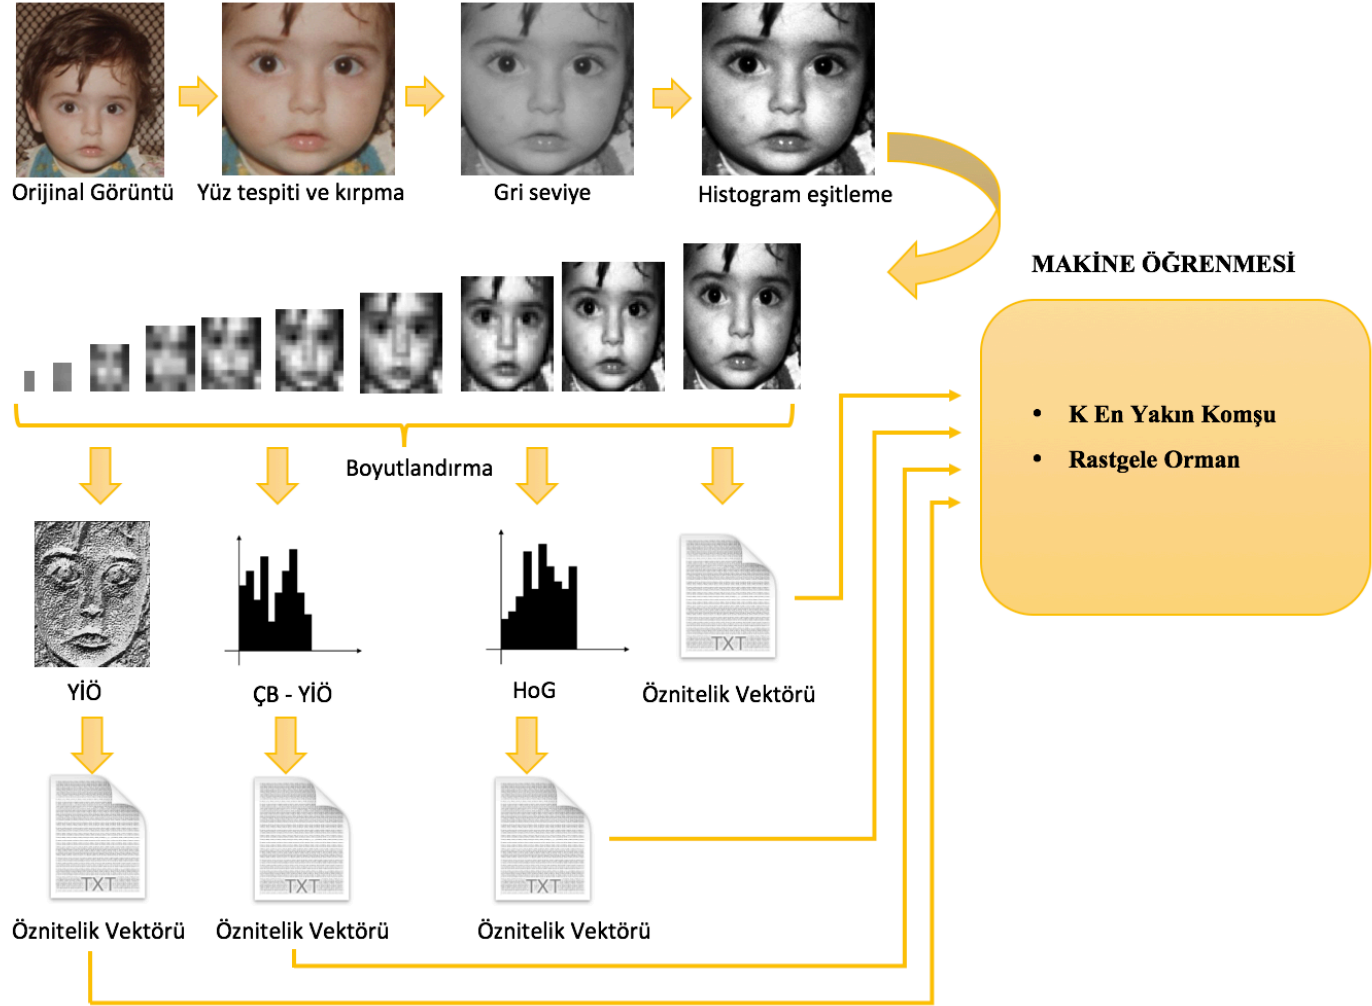
Bu bölümde deneylere başlanmadan önce görüntüler üzerinde yapılan ön işlemler detaylı olarak ele alınacaktır. Deneylerde MORPH ve FG-NET olmak üzere iki farklı görüntü veri tabanı kullanılmıştır. MORPH ve FG-NET yapı ve özellik itibarıyla birbirinden farklıdır. Bu farklılıklar detaylı olarak Bölüm 3.2’de ele alınmıştır. Bu yüzden MORPH ve FG-NET veri tabanlarına ait görüntülere uygulanan ön işlemler farklılık göstermektedir. Bu farklılıklar aşağıdaki gibidir.

- MORPH veri tabanında yaş aralıklarına göre dağılım düzgün olmadığından yaş aralığı seçimi sadece MORPH veri tabanına uygulanmıştır.
- MORPH veri tabanında 55134 adet, FG-NET veri tabanında ise 1002 görüntü olduğundan, alt örnekleme ile görüntü sayısını azaltma işlemi sadece MORPH veri tabanında yapılmıştır.
- Genele bakıldığında MORPH veri tabanındaki görüntülerde kişilerin kafa pozisyonu daha kontrolsüz olduğundan ve ilk önce MORPH veri tabanına uygulanan göz hizalama işleminin başarımlarına önemli bir katkısı olmamasından, göz orta noktalarını hizalama işlemi sadece MORPH veri tabanına uygulanmıştır.

Şekil 4.1 ve Şekil 4.2 sırasıyla MORPH ve FG-NET veri tabanına ait görüntülere uygulanan ön işlemler örnek bir görüntü üzerinde gösterilmiştir.




Şekil 4.1: Örnek bir görüntü üzerinde MORPH veri tabanında yapılan ön işlemler.




Şekil 4.2: Örnek bir görüntü üzerinde FG-NET veri tabanında yapılan ön işlemler.

4.1 Yaş Aralığı Seçimi

Geçmişte MORPH veri tabanı kullanılarak yapılan çalışmalar incelendiğinde [32]'de yeterli test ve eğitim görüntüsü olmadığı gerekçesiyle 55 yaş üzeri görüntülerin kullanılmadığı görülmüş ve 55 yaş üzeri görüntüler elenmiştir. Eleme işleminden sonra görüntü sayısı 53620'ye düşmüştür. Öncelikle MORPH veri tabanında yaş sınıfları <20, 20-29, 30-39, 40-49, 50-55 şeklinde ayrılmış, daha sonra bu ayrımın bir veya iki yaklaşık doğru yaş tahmininde bile, iki değer aynı gruba ait olmaması durumunda sonucun yanlış olarak değerlendirildiği görülmüştür. Bu duruma engel olmak amacıyla 2012'de yapılan bir çalışmadaki gibi [34] iç içe geçmiş yaş aralıkları kullanılmıştır. MORPH veri tabanı için kullanılan iç içe geçmiş yaş grupları Şekil 4.3'te, FG-NET veri tabanı için kullanılan iç içe geçmiş yaş grupları Şekil 4.4'te gösterilmiştir.



Şekil 4.3: MORPH veri tabanı için iç içe yaş grupları.



Şekil 4.4: FG-NET veri tabanı için iç içe yaş grupları.

4.2 Alt Örnekleme

MORPH veri tabanındaki görüntü sayısının çok fazla olması deney sürelerini olumsuz etkileyeceğinden, veri tabanı alt örnekleme işlemine tabi tutularak veri tabanının %10'u deneylerde kullanılmıştır. Alt örnekleme yaparken yaş ve cinsiyet dağılımına göre görüntü sayısı oranları korunmuştur. Görüntüler rastgele seçilmiş,

rastgele seçilen görüntüdeki kişiye ait tüm görüntüler çalışmada kullanılmak üzere alt örnek içine alınmıştır. Alt örnekleme öncesi ve sonrası yaş ve cinsiyete göre görüntü sayı ve yüzdeleri Çizelge 4.1 ve Çizelge 4.2’de gösterilmiştir.

Çizelge 4.1: Alt örnekleme öncesi yaş ve cinsiyet dağılımı sayı ve yüzdeleri.



	16-20	20-29	30-39	40-49	50-55	TOPLAM
ERKEK	6548 (%88.75)	13888 (%85.82)	12345 (%80.98)	9931 (%83.39)	2563 (%88.17)	45,275 (%84.44)
KADIN	830 (%11.25)	2294 (%14.18)	2899 (%19.02)	1978 (%16.61)	344 (%11.83)	8,345 (%15.56)
TOPLAM	7378 (%13.76)	16182 (%30.18)	15244 (%28.43)	11909 (%22.21)	2907 (%5.42)	53,620

Çizelge 4.2: Alt örnekleme sonrası yaş ve cinsiyet dağılımı sayı ve yüzdeleri.

	16-20	20-29	30-39	40-49	50-55	TOPLAM
ERKEK	655 (%88.75)	1389 (%85.82)	1234 (%80.98)	993 (%83.39)	256 (%88.17)	4527 (%84.44)
KADIN	83 (%11.25)	229 (%14.18)	290 (%19.02)	198 (%16.61)	35 (%11.83)	835 (%15.56)
TOPLAM	738 (%13.76)	1618 (%30.18)	1524 (%28.43)	1191 (%22.21)	291 (%5.42)	5362

4.3 Göz Orta Noktalarının Hizalanması


MORPH veritabanındaki görüntülerde göz orta noktalarının aynı hizada olmaması deney sonuçlarını olumsuz etkileyebileceğinden Viola - Jones Algoritması [Bölüm 3.9] kullanılarak göz orta noktaları tespit edilmiştir. Tespit edilen noktalardan geçen doğrunun x eksenine ile yaptığı açı hesaplanarak görüntü açısı kadar döndürülerek göz orta noktaları hizalanmıştır. Resim 4.1’de göz orta noktalarının tespit edilerek görüntünün döndürülmesi gösterilmiştir.



Resim 4.1: Göz orta noktalarının doğru bir şekilde tespit edilerek görüntünün döndürülmesi.

Viola - Jones Algoritması'nın göz orta noktalarını doğru tespit edememe olasılığına karşı, bulunan göz orta noktaları arasından geçen doğrunun eğimi kontrol edilmiştir. Göz orta noktalarının doğru tespit edilmesi durumunda, iki göz orta noktasından geçen doğrunun eğiminin 0.4 değerini geçmediği gözlemlenmiştir. Bu yüzden doğrunun eğiminin 0.4 değerinden büyük olduğu durumlarda göz orta noktalarının yanlış tespit edildiği varsayılmış ve görüntüler döndürme işlemine tabi tutulmadan kullanılmıştır. Resim 4.2'de Viola - Jones Algoritması'nın göz tespitinde başarısız olduğu örnek durumlar gösterilmiştir.






Resim 4.2: Göz orta noktalarının yanlış tespit edilmesi sebebiyle görüntünün aynı kalması.

4.4 Yüz Tespiti

MORPH veri tabanındaki görüntülerde her ne kadar sadece yüz resmi bulunsa da, arka plandaki piksellerin başarıma olan etkisini en aza indirgeyebilmek amacıyla görüntülerde yüz tespiti yapılmıştır. Yüz tespiti için literatürde en çok kullanılan ve en yüksek başarıma sahip Viola - Jones Algoritması'ndan yararlanılmıştır. Tespit edilen yüz bölgesi kırılarak görüntünün sadece yüz bölgesini içermesi sağlanmıştır. Resim 4.3'te yüz bölgesinin tespit edilmesi ve görüntünün kırılması gösterilmiştir.



Resim 4.3: Yüz bölgesinin tespit edilerek kırılması

4.5 Histogram Eşitlemesi



Histogram, gri seviyeli görüntüde parlaklık değerlerinin dağılımını gösteren grafikdir. Görüntüdeki parlaklık değerlerinin belirli değerlerde yığılması görüntüdeki detayların görülmesini engellediğinden, bu istenen bir durum değildir. Bu yüzden histogram eşitlemesi yapılır. Histogram eşitlemesi sonrasında görüntüdeki parlaklık değerlerinde düzgün bir dağılım olur ve aşırı parlaklık veya karanlık sebebiyle kaybolan detaylar gözle görünür hale gelir. Hesaplama kolaylığı açısından renkli görüntüler önce gri seviyeye dönüştürülerek ardından histogram eşitlemesi işlemi yapılmıştır. Resim 4.4'te histogram eşitlemesi sonucu MORPH veri tabanından görüntü örnekleri üzerinde gösterilmiştir.



Resim 4.4: Histogram eşitlemesi işlemi için sırasıyla, girdi, gri seviye ve çıktı görüntüleri.

4.6 Öznitelik Vektörü Temsili

Görüntüdeki satır sayısı m , görüntüdeki sütun sayısı n olmak üzere, $m \times n$ boyutundaki görüntülerdeki her bir pikselin gri seviyedeki parlaklık değeri soldan sağa ve yukarıdan aşağıya doğru okunarak $1 \times (m \times n)$ boyutundaki öznitelik vektörleri ayrı ayrı metin dosyalarına yazılmıştır. Bu ön işlem sayesinde her bir deney için tek tek öznitelik vektörü oluşturulması ihtiyacı ortadan kalkmış ve deney süreleri azalmıştır. Şekil 4.3'te öznitelik vektörü temsili örnek bir görüntü üzerinde gösterilmiştir.



Şekil 4.5: Görüntüdeki her bir pikselin parlaklık değeri bir matrise yazılır ve matristeki değerler soldan sağa ve yukardan aşağı okunarak tek bir satır halinde metin dosyasına yazılır.



5. DENEY SONUÇLARI VE YORUMLAR

Bu bölümde, 3. ve 4. Bölümlerde anlatılan deneylerin sonuçları ele alınarak, yöntem ve veri tabanına göre kıyaslama yapılmıştır. Tüm deneyler 2x1, 3x2, 6x5, 8x6, 11x9, 16x13, 22x18, 45x36, 90x72, 329x264 olmak üzere on farklı çözünürlükteki görüntüler kullanılarak gerçekleştirilmiştir. Deneylerde, ön işleme tabi tutulmuş görüntülerin piksel parlaklık değerleri (piksel), Orijinal Yerel İkili Örüntüler işlemi ile elde edilen görüntülerin piksel parlaklık değerleri (YİÖ), Çok Bloklü Yerel İkili Örüntüler işlemi ile elde edilen histogram değerleri (MB-LBP) ve Gradyan Yönleri Histogramları işlemi ile elde edilen histogram değerleri (HoG) ayrı ayrı öznitelik olarak kullanılmıştır. MB-LBP ve HoG çıktı olarak histogram verdiklerinden belirli çözünürlüklerden küçük çözünürlüklerde sonuç vermemektedir. Bu yüzden MB-LBP deneyleri 6x5 çözünürlüğünden, HoG deneyleri ise 22x18 çözünürlüğünden başlatılmıştır.

5.1 Cinsiyet Sınıflandırma

Cinsiyet sınıflandırma deneylerinde K-EYK ve RO sınıflandırma yöntemleri kullanılmıştır. FG-NET veri tabanında cinsiyet bilgisi bulunmadığından, cinsiyet ile ilgili deneyler sadece MORPH veri tabanı ile gerçekleştirilmiştir. Bu yüzden cinsiyet ile ilgili deney sonuçları ayrı ve tek olarak değerlendirilecektir.

5.1.1 K-EYK ile cinsiyet sınıflandırma


K-EYK sınıflandırma algoritması kullanılarak MORPH veri tabanında gerçekleştirilen cinsiyet sınıflandırma deneylerinin başarımları Çizelge 5.1'de verilmiştir. Her bir çözünürlükte, kullanılan öznitelik bazında, on farklı K değeri için başarımları grafikler halinde Şekil 5.1'de gösterilmiştir.

Çizelge 5.1: On farklı çözünürlükte, farklı K değerleri ve dört farklı öznelik için K-EYK cinsiyet sınıflandırma başarımları yüzdeleri.


Boyut	Öznelik	K=1	K=3	K=5	K=7	K=9	K=11	K=13	K=15	K=25	K=35
2x1	Piksel	%85.6	%83.6	%83.2	%83.2	%83.7	%83.2	%83.4	%83	%83.3	%83.7
	YİÖ	%84.4	%84.4	%84.4	%84.4	%84.4	%84.4	%84.4	%84.4	%84.4	%84.4
	ÇB-YİÖ	-	-	-	-	-	-	-	-	-	-
	HoG	-	-	-	-	-	-	-	-	-	-
3x2	Piksel	%76.2	%80.6	%82	%83.1	%83.7	%83.8	%84	%83.8	%84.2	%84.4
	YİÖ	%85.8	%83	%84.4	%84.4	%83.9	%76.8	%84	%84.3	%83.7	%82.3
	ÇB-YİÖ	-	-	-	-	-	-	-	-	-	-
	HoG	-	-	-	-	-	-	-	-	-	-
6x5	Piksel	%86.1	%86.9	%87.1	%87.3	%87.1	%86.8	%86.9	%86.7	%86	%85.6
	YİÖ	%80.9	%83.8	%84.5	%84.6	%85	%84.9	%84.8	%84.9	%85.1	%85
	ÇB-YİÖ	%80.3	%82.4	%83.6	%84.2	%84.4	%84.4	%84.2	%84.1	%84.3	%84.4
	HoG	-	-	-	-	-	-	-	-	-	-
8x6	Piksel	%87.7	%88.3	%88.5	%88	%87.7	%87.6	%87.6	%87.2	%86.5	%85.9
	YİÖ	%92.2	%89.7	%88.6	%87.6	%87.3	%86.8	%86.6	%86.3	%85.5	%85.2
	ÇB-YİÖ	%79.7	%82.7	%83.9	%84.3	%84.6	%84.7	%84.6	%84.6	%84.7	%84.7
	HoG	-	-	-	-	-	-	-	-	-	-
11x9	Piksel	%96.9	%93.8	%91.9	%90.9	%90.6	%89.9	%89.4	%88.9	%87.9	%87.2
	YİÖ	%100	%91.9	%90.1	%89.2	%88.6	%87.9	%87.5	%87.3	%86.2	%85.9
	ÇB-YİÖ	%80.5	%83.5	%84.1	%84.7	%84.9	%84.9	%85	%85.1	%85	%84.9
	HoG	-	-	-	-	-	-	-	-	-	-
16x13	Piksel	%100	%95	%93.3	%92	%91.4	%91	%90.7	%89.9	%88.7	%88
	YİÖ	%100	%94.2	%92.9	%92	%91	%90.5	%90	%89.6	%88.3	%87.4
	ÇB-YİÖ	%78.5	%83.3	%84	%84.5	%84.7	%84.7	%84.8	%84.7	%84.9	%84.9
	HoG	-	-	-	-	-	-	-	-	-	-
22x18	Piksel	%100	%95.6	%93.7	%92.5	%91.8	%91.4	%91	%90.6	%89.3	%88.4
	YİÖ	%100	%95.5	%93.6	%92.4	%91.8	%90.9	%90.5	%90.2	%88.6	%87.8
	ÇB-YİÖ	%78.8	%83	%83.7	%84.2	%84.8	%84.9	%84.9	%84.9	%84.8	%84.6
	HoG	%85.4	%87	%87	%87	%86.7	%86.6	%86.4	%86.2	%85.9	%85.3
45x36	Piksel	%100	%95.5	%93.9	%93	%92.4	%92	%91.6	%91.3	%90.2	%89.1
	YİÖ	%100	%96.1	%94.7	%94	%93	%92.4	%91.9	%91.4	%89.8	%89
	ÇB-YİÖ	%80.4	%84.6	%85	%85.5	%85.4	%85.5	%85.4	%85.3	%84.9	%84.7
	HoG	%98.9	%97	%95.8	%95	%94.1	%93.4	%93	%92.2	%90.4	%89.3
90x72	Piksel	%100	%95.4	%93.8	%92.6	%92.4	%91.9	%91.4	%91	%89.9	%89.3
	YİÖ	%100	%95	%93.6	%93	%92.4	%91.9	%91.2	%90.9	%89.5	%88.8
	ÇB-YİÖ	%82.5	%84.8	%85.4	%85.4	%85.4	%85.4	%85.4	%85.1	%84.9	%84.6
	HoG	%100	%98.1	%97.2	%96	%95.3	%94.7	%94.4	%93.9	%92.3	%90.5
329 x 264	Piksel	%100	%95.4	%93.6	%92.7	%92	%91.8	%91.4	%91	%90	%89
	YİÖ	%100	%87.2	%86.2	%85.9	%85.7	%85.9	%86.5	%87	%88	%88.3
	ÇB-YİÖ	%81	%84	%84.7	%85.2	%85.1	%85.2	%85.2	%85.2	%87.7	%84.6
	HoG	%100	%95.2	%93	%91.3	%90.1	%89.5	%88.8	%88.2	%86.6	%85.7




Şekil 5.1: On farklı çözünürlükte, dört farklı öznetelik için K-EYK cinsiyet sınıflandırma başarımları yüzdesi grafikleri.



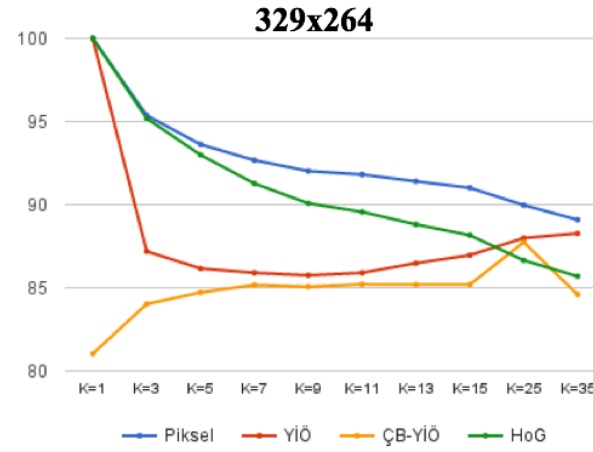
(g)



(h)



(i)



(j)

Şekil 5.1: On farklı çözünürlükte, dört farklı öznelik için K-EYK cinsiyet sınıflandırma başarımları yüzdesi grafikleri (devam).

K-EYK ile cinsiyet sınıflandırma başarımları yüzdeleri göz önünde bulundurulduğunda, sadece iki pikselden oluşan ve insan gözü için hiçbir şey ifade etmeyen 2x1 çözünürlüğünde, en kötü durumda bile (K=35) %80'in üzerinde başarımlar elde edildiği görülmektedir. Sadece iki ihtimalin bulunduğu cinsiyet sınıflandırmasında, rastgele verilen kararda cinsiyetin doğru olma ihtimali %50 olduğundan, %80 ve üzeri başarımlar bu başarımların çok üzerinde olduğundan, 2x1 çözünürlüğündeki görüntülerin bile cinsiyete ait bilgiler barındırdığını söylemek mümkündür.

11x9 çözünürlüğünden itibaren K=1 için, cinsiyet sınıflandırmasında %100 başarımlara ulaşılmasının sebebinin, MORPH veri tabanında aynı kişiye ait ortalama dört görüntünün bulunması ve bir görüntüye ait en yakın görüntünün aynı kişinin bir başka görüntüsü olması olduğu düşünülmektedir.

Kullanılan öznelik bazında tüm çözünürlüklerdeki başarımlar oranı düşünüldüğünde, piksel parlaklık değerleri kullanılarak diğer özneliklere göre daha yüksek başarımlar oranı elde edildiği görülmektedir. Bunun sebebinin, cinsiyet tespiti için gerekli olan bilgilerin piksel parlaklık değerleriyle taşınması olduğu düşünülmektedir.


Sonuçlardan 16x13 çözünürlüğünde kabul edilebilir başarımlara ulaşıldığı ve bu çözünürlükten itibaren çözünürlüğü arttırmanın başarımlar oranına ciddi bir katkı sağlamadığı görülmektedir.

5.1.2 RO ile cinsiyet sınıflandırma

RO ile cinsiyet sınıflandırma başarımlar yüzdeleri Çizelge 5.2'de gösterilmiştir. Öznelik ve çözünürlük bazında başarımlar oranı grafiği Şekil 5.2'de verilmiştir.

Çizelge 5.2: On farklı çözünürlük ve dört farklı öznelik için RO cinsiyet sınıflandırma başarımlar yüzdeleri.

ÖZNE- TELİK	BOYUT									
	2x1	3x2	6x5	8x6	11x9	16x13	22x18	45x36	90x72	329x26
Piksel	%83.8	%82.3	%86.4	%86.3	%87.0	%87.2	%87.3	%87.9	%88.0	%88.47
YİÖ	%84.4	%83.8	%84.6	%84.7	%85	%85	%84.9	%84.5	%84.4	%84.4
ÇB- YİÖ	-	-	%84.2	%84.5	%84.5	%84.5	%84.5	%84.7	%85.2	%85
HoG	-	-	-	-	-	-	%86.4	%87.9	%88.3	%85.96



Şekil 5.2: On farklı çözünürlük ve dört farklı öznitelik için RO ile cinsiyet sınıflandırma başarımlarının yüzde grafiği.

RO sınıflandırıcısı ile cinsiyet sınıflandırma başarımları incelendiğinde minimum %82.3 başarımla cinsiyetin sınıflandırılabilir olduğu görülmektedir. En yüksek başarımla %88.47 oranı ile piksel parlaklık değerlerinin öznitelik olarak kullanılması ile elde edilmiştir. Piksel parlaklık değeri öznitelik olarak kullanılarak yapılan deneylerde en yüksek başarımla artışının 3x2 çözünürlüğünden 6x5 çözünürlüğüne geçişte elde edildiği, 11x9 çözünürlüğünden itibaren başarımlarında ciddi bir artış olmadığı görülmektedir.

Cinsiyet sınıflandırmada RO ve K-EYK sınıflandırıcıları birlikte değerlendirildiğinde cinsiyet sınıflandırmada öznitelik olarak piksel parlaklık değerinin tek başına yeterli olduğu, 16x13 çözünürlüğünden itibaren her iki sınıflandırıcı için de başarımlarda ciddi bir artış görülmediğini söylemek mümkündür.

5.2 Yaş Sınıflandırma

FG-NET ve MORPH veri tabanları yaş bilgisi içerdiğinden, yaş sınıflandırma deneyleri her iki veri tabanına ait görüntülerde de gerçekleştirilmiştir. Deneyler öncelikle MORPH veri tabanında ayrık yaş grupları ile yapılmış, daha sonra bu ayrımın bir veya iki yaklaşık doğru yaş tahmininde bile, iki değer ayrı gruba ait olmaması durumunda sonucun yanlış olarak değerlendirildiği görülmüştür. Bu duruma engel olmak amacıyla önceki bir çalışmada [34] kullanılan iç içe yaş gruplarıyla tekrarlanmıştır. İç içe yaş grupları kullanmanın başarımlara önemli katkısı

gözelemlendiğinden FG-NET veri tabanına ait görüntülerde yapılan deneylerde sadece iç içe yaş grupları kullanılmıştır. Her iki veri tabanında kullanılan yaş grupları aralıkları Bölüm 4.1’de verilmiştir.

5.2.1 K-EYK ile yaş sınıflandırma

K-EYK ile yaş sınıflandırma deneyleri, MORPH veri tabanına ait görüntülerle, ayırık yaş grupları, MORPH veri tabanına ait görüntülerle, iç içe yaş grupları ve FG-NET veri tabanına ait görüntülerle, iç içe yaş grupları ile olmak üzere üç kez tekrarlanmıştır. Bu deneylere ait başarımlar yüzdeleri sırasıyla Çizelge 5.3, Çizelge 5.4 ve Çizelge 5.5’te verilmiştir. Her çözünürlük için üç kez tekrarlanan deney sonuçları grafikleri ayrı ayrı incelenerek yorumlanacaktır. 2x1 ve 3x2 çözünürlüğü için başarımlar grafikleri Şekil 5.3 ve Şekil 5.4’te verilmiştir.

Çizelge 5.3: On farklı çözünürlükte, farklı K değerleri ve dört farklı öznitelik için MORPH veri tabanı K-EYK yaş sınıflandırma başarımlarının yüzdeleri.


Boyut	Öznitelik	K=1	K=3	K=5	K=7	K=9	K=11	K=13	K=15	K=25	K=35
2x1	Piksel	%16.5	%14.6	%14.8	%19.4	%20.7	%20.8	%20.8	%20.6	%16.9	%15.2
	YİÖ	%6.8	%6.5	%6.5	%6.5	%6.5	%6.5	%6.5	%6.5	%6.5	%6.5
	ÇB-YİÖ	-	-	-	-	-	-	-	-	-	-
	HoG	-	-	-	-	-	-	-	-	-	-
3x2	Piksel	%26.1	%18.6	%14.4	%12.4	%11.2	%10.3	%9.4	%8.6	%6.2	%4.9
	YİÖ	%12.6	%10.2	%9.2	%9.1	%10.7	%13.6	%14.1	%17.8	%17.7	%16.2
	ÇB-YİÖ	-	-	-	-	-	-	-	-	-	-
	HoG	-	-	-	-	-	-	-	-	-	-
6x5	Piksel	%41.8	%32.8	%28.7	%25.3	%22.6	%20.2	%18.7	%17.3	%12.2	%9.6
	YİÖ	%32.5	%25.2	%20.6	%17.6	%15.5	%14	%12.8	%11.9	%7.7	%5.9
	ÇB-YİÖ	%26.7	%17.3	%13.3	%10.7	%8.7	%7.3	%6	%5	%3	%2.1
	HoG	-	-	-	-	-	-	-	-	-	-
8x6	Piksel	%44.8	%36.5	%31.4	%27.1	%24.2	%22.5	%20.9	%19.2	%13.5	%10.1
	YİÖ	%69.8	%45.5	%34.8	%27.5	%23.1	%19	%16.4	%14.1	%8.3	%6
	ÇB-YİÖ	%26.3	%17.4	%13	%10.5	%8.3	%6.7	%5.7	%5	%2.3	%1
	HoG	-	-	-	-	-	-	-	-	-	-
11x9	Piksel	%80.3	%61.3	%49.3	%41.6	%36.5	%32.5	%28.7	%26.6	%19.2	%14.1
	YİÖ	%97.1	%57.9	%43.7	%34.9	%28.7	%24.4	%21.3	%18.7	%10.9	%7.1
	ÇB-YİÖ	%26.3	%18.1	%13.8	%10.5	%9.3	%7.4	%6.1	%5.4	%2.3	%1.1
	HoG	-	-	-	-	-	-	-	-	-	-
16x13	Piksel	%97.1	%67.7	%54.2	%45.9	%40.0	%35.4	%31.6	%28.9	%19.2	%14.8
	YİÖ	%97.1	%62.4	%48.6	%34.4	%34	%29.2	%25.7	%22.8	%13	%8.8
	ÇB-YİÖ	%26.7	%18.2	%14.4	%11.4	%9.4	%7.7	%6.1	%5	%2.1	%1.1
	HoG	-	-	-	-	-	-	-	-	-	-
22x18	Piksel	%97.1	%68.7	%54.5	%46.7	%40.5	%36.6	%37.9	%30.1	%20.5	%15
	YİÖ	%97.1	%67.2	%52.4	%43.1	%36.7	%31.7	%28.1	%24.5	%14.1	%9.5
	ÇB-YİÖ	%27.8	%19.3	%15.2	%12.3	%9.6	%8.1	%6.8	%6	%3.2	%2.2
	HoG	%36.2	%26.8	%21.3	%17.6	%14.3	%12.1	%10.5	%8.9	%4.3	%2.8
45x36	Piksel	%97.1	%68.8	%55.3	%47	%41.8	%37.1	%33.7	%30.2	%20.6	%15.3
	YİÖ	%97.1	%68.1	%53.9	%44.3	%38.0	%32.3	%28.5	%25.1	%15.5	%10.4
	ÇB-YİÖ	%31.0	%23.5	%19.2	%16.6	%14	%11.8	%10.4	%9.2	%6	%4.9
	HoG	%87.6	%76.0	%66.1	%59.7	%53	%47.3	%43.5	%40	%26.3	%17.7
90x72	Piksel	%97.1	%68	%54.6	%46.3	%41.4	%37.1	%32.9	%29.7	%20.5	%15.3
	YİÖ	%97.1	%61.8	%47.4	%39.2	%32.9	%28.1	%24.9	%21.8	%14.1	%10.7
	ÇB-YİÖ	%35.8	%29.2	%25.6	%22.8	%21	%18.9	%17.3	%16.6	%12.9	%10.9
	HoG	%97.1	%83.4	%74.2	%66.4	%60.5	%55.5	%51.5	%48.5	%34.8	%26.9
329 x 264	Piksel	%97.1	%67.9	%53.9	%46.4	%41.2	%36.8	%33.1	%30	%20.9	%15.6
	YİÖ	%97.1	%49	%39.1	%34.8	%32.9	%30.9	%29.8	%28.9	%27	%26.2
	ÇB-YİÖ	%34.9	%31.0	%27.6	%26.3	%24.8	%23.7	%23	%22.3	%20.1	%18.1
	HoG	%97.1	%68.5	%53.3	%43.9	%37.9	%33.2	%28.9	%25.5	%15.3	%10.5

Çizelge 5.4: On farklı çözünürlükte farklı K değerleri ve dört farklı öznelik için MORPH veri tabanı K- EYK içiçe yaş grupları ile yaş sınıflandırma başarımları yüzdeleri.


Boyut	Öznelik	K=1	K=3	K=5	K=7	K=9	K=11	K=13	K=15	K=25	K=35
2x1	Piksel	%31	%29.9	%30.4	%31.6	%32.6	%33.1	%32.6	%34.3	%39.4	%40.3
	YİÖ	%25.7	%25.7	%25.7	%25.7	%25.7	%25.7	%25.7	%25.7	%25.7	%27.1
	ÇB-YİÖ	-	-	-	-	-	-	-	-	-	-
	HoG	-	-	-	-	-	-	-	-	-	-
3x2	Piksel	%43.6	%41.2	%39.6	%38.8	%37.8	%36.9	%36.7	%36.1	%34.5	%33.6
	YİÖ	%31.3	%29.3	%29.1	%28.9	%30.3	%30.7	%30.7	%31.5	%33.7	%34.5
	ÇB-YİÖ	-	-	-	-	-	-	-	-	-	-
	HoG	-	-	-	-	-	-	-	-	-	-
6x5	Piksel	%56.8	%54.3	%52.7	%52.6	%51.6	%50.9	%50.7	%50.1	%47.6	%45.6
	YİÖ	%47.4	%45.7	%45.5	%44.2	%43	%42.9	%42.5	%42	%40.8	%39.2
	ÇB-YİÖ	%28.4	%37.3	%35.6	%32.7	%32.4	%31.6	%31	%30.2	%28.3	%26.8
	HoG	-	-	-	-	-	-	-	-	-	-
8x6	Piksel	%58.6	%57.3	%55	%53.4	%53.6	%53.1	%52.4	%51.1	%48.7	%46.4
	YİÖ	%76.7	%64.6	%59.3	%55.1	%52.8	%50.7	%48.7	%47.3	%42.1	%39.6
	ÇB-YİÖ	%26.3	%38.5	%36	%34.8	%33.3	%32.5	%32.4	%31.4	%28.6	%26.5
	HoG	-	-	-	-	-	-	-	-	-	-
11x9	Piksel	%84.9	%75.8	%70.7	%67	%64.4	%63.1	%60.7	%59.4	%54.9	%51.9
	YİÖ	%97.1	%72.8	%65.6	%61.4	%57.4	%55	%52.6	%51.3	%46.3	%43.1
	ÇB-YİÖ	%26.3	%39.1	%39.9	%35.7	%34.2	%33.8	%32.6	%31.5	%29.3	%27.7
	HoG	-	-	-	-	-	-	-	-	-	-
16x13	Piksel	%97.2	%80.1	%73.3	%69.7	%66.9	%64.3	%62.8	%61.1	%56	%53.1
	YİÖ	%97.1	%76.6	%69.6	%64.9	%62.0	%59.6	%57.7	%56.7	%50.8	%46.6
	ÇB-YİÖ	%26.7	%39.0	%37.3	%36.1	%35.6	%34.9	%33.1	%32.1	%29.6	%27.1
	HoG	-	-	-	-	-	-	-	-	-	-
22x18	Piksel	%97.1	%80.5	%74	%70.4	%67.5	%65.3	%62.8	%62	%56.8	%53.2
	YİÖ	%97.1	%78.7	%71.9	%67.7	%63.9	%61.4	%59.6	%57.6	%51.6	%47.9
	ÇB-YİÖ	%27.8	%41.7	%40.1	%38.4	%37.2	%36.4	%35.1	%34.3	%32	%30
	HoG	%49.8	%46.8	%44	%42.2	%40.5	%39.3	%38.6	%37.6	%34.9	%32
45x36	Piksel	%97.1	%81.1	%74.4	%70.1	%67.7	%65.2	%64.1	%62.5	%57.6	%54
	YİÖ	%97.1	%79.7	%71.2	%66.6	%62.4	%59.2	%57.4	%55.9	%50.2	%46.5
	ÇB-YİÖ	%31	%45.7	%44.3	%44.3	%43.8	%43.1	%42.7	%42.3	%41.3	%39.9
	HoG	%90.8	%85.1	%80.7	%78.1	%75.7	%73.5	%71.6	%70.2	%65.6	%61.2
90x72	Piksel	%97.1	%80.6	%73.7	%69.5	%66.9	%65.3	%64	%62.2	%57.4	%53.9
	YİÖ	%97.1	%74.1	%65	%60	%56.4	%53.9	%52	%50.1	%45.6	%44.2
	ÇB-YİÖ	%35.8	%52	%51.8	%51.6	%51.1	%50.9	%50.4	%50.4	%50	%49
	HoG	%97	%90.1	%86.6	%83.3	%81.6	%79.8	%78.4	%77.1	%73.5	%70.5
329 x 264	Piksel	%97.1	%80.3	%73.4	%69.5	%66.8	%65	%63.4	%61.6	%57.4	%54.3
	YİÖ	%97.1	%66.6	%60.2	%57.5	%55.7	%54.8	%54.6	%54	%53.3	%53
	ÇB-YİÖ	%34.9	%55.1	%55.5	%55.3	%54.4	%53.8	%54.1	%54.1	%53.8	%53.2
	HoG	%97.1	%80.5	%73.4	%69.3	%66	%63	%61.5	%59.5	%53.4	%49.6

Çizelge 5.5: On farklı çözünürlükte farklı K değerleri ve dört farklı öznelik için FG-NET veri tabanı K- EYK içiçe yaş grupları ile yaş sınıflandırma başarımlarının yüzdeleri.


Boyut	Öznelik	K=1	K=3	K=5	K=7	K=9	K=11	K=13	K=15	K=25	K=35
2x1	Piksel	%41.6	%20.3	%20.4	%21.2	%20.2	%21.4	%21.4	%18.5	%21.4	%19.3
	ÇB-YİÖ	-	-	-	-	-	-	-	-	-	-
	YİÖ	%36.1	%25.5	%30.4	%36.5	%36.8	%15.3	%15.3	%15.3	%15.3	%0
	HoG	-	-	-	-	-	-	-	-	-	-
3x2	Piksel	%30.6	%26.2	%24.9	%24.5	%23.3	%23.3	%22.1	%21.3	%20.2	%20.4
	ÇB-YİÖ	-	-	-	-	-	-	-	-	-	-
	YİÖ	%43.5	%25.6	%25.2	%21.3	%23	%21.4	%20.4	%19.9	%18.9	%18.7
	HoG	-	-	-	-	-	-	-	-	-	-
6x5	Piksel	%39	%34.8	%34.7	%31.9	%31.1	%30.9	%31.2	%30.9	%27.9	%25.3
	ÇB-YİÖ	%32.8	%29.9	%25.8	%24.8	%22.8	%20.9	%19.2	%18.1	%17.3	%15.3
	YİÖ	%43	%35.8	%30.9	%31.6	%27.6	%26.8	%27	%26.9	%24.5	%22.1
	HoG	-	-	-	-	-	-	-	-	-	-
8x6	Piksel	%47.7	%42.5	%40.5	%38.4	%37.6	%36.6	%33.6	%34.9	%31.9	%30.6
	ÇB-YİÖ	%35.4	%30.9	%28	%26.5	%24.4	%24	%23.8	%21.7	%19.1	%17.8
	YİÖ	%87.9	%54.4	%46.5	%42.8	%37.9	%35.8	%35.5	%33.7	%29.8	%26.9
	HoG	-	-	-	-	-	-	-	-	-	-
11x9	Piksel	%92.1	%60.8	%51.2	%46.9	%43.1	%42.2	%41.8	%40.1	%36.5	%34.0
	ÇB-YİÖ	%33.3	%26.6	%26.5	%24.7	%24.2	%24.1	%23.1	%20.9	%20	%19.1
	YİÖ	%96.2	%59.4	%53	%48.4	%45.1	%44.5	%43.8	%42.8	%40.8	%38.7
	HoG	-	-	-	-	-	-	-	-	-	-
16x13	Piksel	%96.2	%61.5	%54.6	%50.3	%47.7	%45.8	%45.7	%44.1	%38.7	%35.8
	ÇB-YİÖ	%34.2	%28.8	%26.9	%27.6	%27.2	%24.3	%23.8	%22.7	%21.2	%21.1
	YİÖ	%96.2	%62.5	%54.1	%48.6	%48.2	%47.4	%46.1	%45.7	%42.3	%40
	HoG	-	-	-	-	-	-	-	-	-	-
22x18	Piksel	%96.2	%62.1	%54.2	%50.4	%48.9	%47	46%	%44.4	%39.5	%36.8
	ÇB-YİÖ	%34.6	%31.7	%29.9	%28.1	%26.3	%25.5	%24.7	%24.9	%23.3	%22.1
	YİÖ	%96.2	%63.9	%57.0	%52.0	%49.7	%47.8	%47.4	%47	%43.2	%41.1
	HoG	%34.1	%32.3	%28.1	%27.3	%24.9	%24.4	%22.3	%21.6	%19.4	%19.3
45x36	Piksel	%96.2	%62.2	%53.7	%51.1	%49.3	%46.8	%46.2	%45.2	%40.9	%38
	ÇB-YİÖ	%38.2	%34.3	%31.5	%29.3	%28.2	%27.3	%27.1	%25.7	%23.1	%22.6
	YİÖ	%96.2	%62.8	%55.3	%52.7	%49.8	%48.1	%46.3	%46.4	%44.1	%42.5
	HoG	%94.6	%65.4	%52.9	%48.1	%46	%42.8	%41.2	%40.2	%36.1	%34.4
90x72	Piksel	%96.2	%61.9	%52.8	%51.6	%49.7	%48.6	%46.8	%45.4	%41.1	%38.3
	ÇB-YİÖ	%37	%35.3	%31.9	%29.2	%27.9	%26.3	%25.6	%24	%21.4	%19.3
	YİÖ	%96.2	%62.5	%55.7	%51.7	%51.6	%50	%49.7	%49.1	%45.4	%43.8
	HoG	%96.2	%68.4	%56.3	%52.7	%49.5	%45.7	%43.7	%43.9	%40.2	%38.8
329 x 264	Piksel	%96.2	%61.8	%53.6	%51.8	%50.7	%48.9	%46.9	%45.1	%41	%38.8
	ÇB-YİÖ	%37.7	%32.9	%29.8	%26.8	%25.4	%23.2	%23.3	%23.2	%18.4	%17.8
	YİÖ	%96.2	%63	%55.5	%51	%49.5	%47.7	%45.7	%45.1	%40.9	%39.5
	HoG	%96.2	%65.1	%56.1	%54.2	%49.5	%47.8	%47.1	%45.4	%41.4	%40.7



(a)




(b)




(c)


Şekil 5.3: 2x1 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarımlarını gösteren grafiklerdir.



(a)



(b)





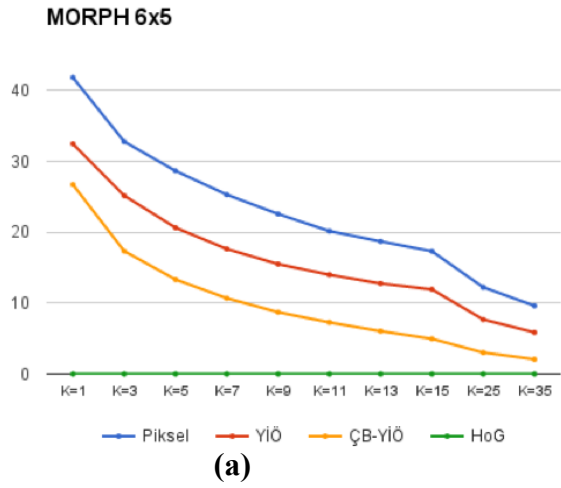
(c)

Şekil 5.4: 3x2 çözünürlüğü için (a) MORPH veri tabanı ile ayrık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarımlarını gösteren grafiklerdir.



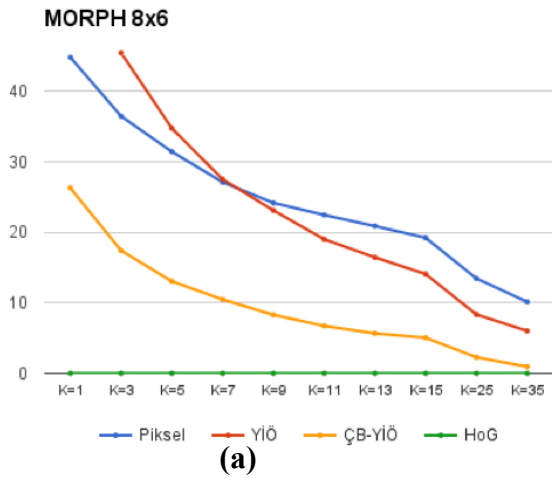
Şekil 5.3'te 2x1 çözünürlüğü için MORPH veri tabanına ait görüntülerde ayrık yaş grupları kullanıldığında elde edilen başarımın, aynı veri tabanına ait görüntülerde iç içe yaş grubu kullanıldığında yaklaşık iki katına çıktığı, öznitelik olarak piksel parlaklık değerlerinin YİÖ'den çok daha yüksek başarım sağladığı Şekil 5.3(a)'da ve Şekil 5.3(b)'de görülmektedir. Şekil 5.3(a)'da ayrık yaş grubu sayısı beştir ve beş grup için elde edilen maksimum yaş sınıflandırma başarımı yaklaşık %20 dir. Bu başarımın hiçbir veriye bakılmaksızın rastgele verilecek kararda doğru olma olasılığından yüksek olmaması ve K değeri arttıkça görüntüler arasındaki benzerlik azalacağından başarımın sürekli düşmesi beklenirken, başarımındaki iniş çıkışlardaki kararsızlık, MORPH veri tabanına ait görüntülerin 2x1 çözünürlüğünde yaş sınıflandırmasında kullanılabilecek bir bilgi içermediği fikrini vermektedir. Şekil 5.3(c)'de FG-NET veri tabanındaki başarımlara bakıldığında, YİÖ özniteliğine ait başarımının piksel parlaklık değerleri özniteliğine göre daha yüksek olduğu fakat K değeri artışında başarımın düşmesi beklenirken başarım oranındaki kararsızlığın bu başarım oranlarının rassal olarak elde edilmiş olduğunu düşündürmektedir. Piksel parlaklığının öznitelik olarak kullanılmasının, K=1 değeri için %40'ın üzerinde başarım sağlaması ve başarımın K=3'te yarı yarıya düşerek rassal değere ulaşmasının sebebinin, FG-NET veri tabanında aynı kişiye ait ortalama oniki görüntü olması ve görüntüye en yakın görüntünün bu oniki görüntüden aynı yaş grubuna denk gelen görüntülerden olması olduğu düşünülmektedir.

Şekil 5.4'te 3x2 çözünürlüğü için K=1'den itibaren başarımın hızlı bir şekilde düşerek rassal değere yaklaşması ve özellikle YİÖ başarım grafiğindeki kararsızlık, Şekil 5.3 için belirtilen sebeplere bağlı olarak 3x2 çözünürlüğünün de yaş sınıflandırmasında kullanılabilecek bir bilgi içermediğini düşündürmektedir.

6x5 ve 8x6 çözünürlüğü için başarım grafikleri sırasıyla, Şekil 5.5 ve Şekil 5.6'da verilmiştir.



Şekil 5.5: 6x5 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.






Şekil 5.6: 8x6 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.

Şekil 5.5'te 6x5 çözünürlüğündeki görüntülerde, ÇB-YİÖ özneliğinin kullanılabilir hale geldiği, fakat tüm durumlar için YİÖ ve piksel parlaklık değeri özneliklerinden çok daha az başarımları sağladığı görülmektedir. Tüm durumlarda piksel parlaklık değeri özneliğinin en iyi başarımları sağladığı, $K=1$ 'den sonra başarımların düşüş hızının azaldığı, iç içe yaş grupları kullanıldığında, en kötü durum olan $K=35$ 'te bile başarımların rassal başarımların olan %20'nin üzerinde olması, 6x5 çözünürlüğünün az da olsa yaş sınıflandırması ile ilgili bilgi içerdiğini göstermektedir.




Şekil 5.6'da 8x6 çözünürlüğündeki görüntülerde daha düşük çözünürlüklerde piksel parlaklık değeri özneliğinden daha az başarımlar sağlayan YİÖ özneliğinin (a)'da piksel parlaklık değeri başarımlarına oldukça yaklaşık başarımlar sağladığı, iç içe yaş gruplarının kullanıldığı (b) ve (c)'de $K=9$ değerine kadar başarımlar anlamında piksel parlaklık değeri özneliğinin önüne geçtiği görülmektedir. İç içe yaş gruplarının kullanılmasında $K=1$ için (b)'de %80'e (c)'de ise %90'a yakın başarımların elde edilmesi, bu çözünürlükten itibaren yaşa ait bilgilerin belirginleştiği, görüntüye en yakın olan görüntülerin, yakın yaşlara sahip ait olduğu ortaya çıkmaktadır.

8x6 çözünürlüğüne ait deney sonuçlarına bakılarak daha yüksek çözünürlüklerde başarımların artması, K değeri arttıkça başarımların düşme hızının azalması beklenmektedir.

11x9 ve 16x13 çözünürlüğü için başarımlar grafikleri sırasıyla, Şekil 5.7 ve Şekil 5.8'de verilmiştir.



Şekil 5.7: 11x9 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.




Şekil 5.8: 16x13 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.


Şekil 5.7’de 11x9 çözünürlüğünde, (a)’da $K=1$ değeri için YİÖ’deki başarımların maksimum değeri olan %97.01’e ulaşırken, piksel parlaklık değeri başarımlarını %80’de kalmıştır. Her üç durumda da $K=1$ değeri için maksimum başarımların YİÖ özneliği ile elde edilmiştir. MORPH ayrık yaş grupları için maksimum başarımların 8x6 çözünürlüğünün yaklaşık iki katına ulaşmıştır. MORPH iç içe yaş grupları ve FG-NET iç içe yaş grupları için ise başarımlardaki artış daha azdır. ÇB-YİÖ özneliği için ise, 8x6 çözünürlüğünden 11x9 çözünürlüğüne geçişte her üç durumda da bir artış görülmemektedir. Üç durum için maksimum başarımların %97.01’e ilk kez 11x9 çözünürlüğünde, YİÖ özneliğiyle yapılan deneylerde ulaşılmıştır. $K=1$ ’den $K=3$ ’e geçildiğinde başarımlardaki en büyük düşüş FG-NET veri tabanında yaşanmıştır. Bunun sebebinin FG-NET veri tabanındaki yaş aralığının MORPH veri tabanındaki yaş aralığından daha geniş olması ve görüntüye en yakın olarak seçilen görüntünün başka bir yaş grubuna ait olması olasılığının daha yüksek olması olduğu düşünülmektedir.

Şekil 5.8’de 16x13 çözünürlüğünde 11x9 çözünürlüğüne göre başarımlarda ciddi bir artış gözlemlenmemekle beraber piksel parlaklık değeri öznelikleri ve YİÖ özneliklerinin başarımların yüzdelerinin birbirine yaklaştığı görülmektedir.


22x18 ve 45x36 çözünürlüğü için başarımların grafikleri sırasıyla, Şekil 5.9 ve Şekil 5.10’da verilmiştir.



(a)




(b)




(c)


Şekil 5.9: 22x18 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.



(a)



(b)




(c)

Şekil 5.10: 45x36 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.


Şekil 5.9'da 22x18 çözünürlüğünde HoG özneliği de kullanılmış fakat ÇB-YİÖ özneliği başarımına yakın ve oldukça düşük başarım elde edilmiştir. Pikel parlaklık değeri özneliği ve YİÖ özneliği başarım oranlarında bir artış görülmemektedir.

Şekil 5.10'da 45x36 çözünürlüğünde (a)'da HoG özneliğine ait başarımın çok hızlı bir şekilde artarak pikel parlaklık değeri özneliği ve YİÖ özneliğine yakın başarım sağladığı görülmektedir. (b)'de HoG özneliğinin başarımı daha da artarak, ortalama YİÖ ve pikel parlaklık değeri özneliğinin başarım oranlarının önüne geçmiştir. (b)'de HoG özneliğinin, en kötü durum olan K=35 değeri için bile %60'ın üzerinde başarım oranı sağlaması, K=1 değerine ait başarımı diğer iki öznelikten düşük olmasına rağmen tercih sebebidir. (c)'de ise YİÖ, HoG ve pikel parlaklık değeri öznelikleri birbirlerine çok yakın başarım oranları sağlamıştır. MORPH veri tabanındaki en kötü durum olan K=35 değeri için elde edilen başarım, FG-NET veri tabanındaki K=35 değeri için elde edilen başarımından oldukça yüksektir. MORPH veri tabanı iç içe yaş grupları için en yüksek başarımı veren öznelik sıralaması HoG > Pikel > YİÖ iken, bu sıralama FG-NET veri tabanı iç içe yaş grupları için YİÖ > Pikel > HoG şeklindedir.


90x72 ve 329x264 çözünürlüğü için başarım grafikleri sırasıyla, Şekil 5.11 ve Şekil 5.12'da verilmiştir.



(a)




(b)




(c)


Şekil 5.11: 90x72 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.



(a)



(b)



(c)

Şekil 5.12: 329x264 çözünürlüğü için (a) MORPH veri tabanı ile ayrıık yaş grupları, (b) MORPH veri tabanı ile iç içe yaş grupları, (c) FG-NET veri tabanı ile iç içe yaş grupları, K-EYK ile yaş sınıflandırma başarıım yüzde grafikleri.

Şekil 5.11’de 90x72 çözünürlüğünde yapılan deneylerde, (a) ve (b)’de sadece HoG ve ÇB-YİÖ özniteliklerine ait deney sonuçlarında başarımların arttığı, geriye kalan piksel parlaklık değeri ve YİÖ özniteliklerine ait başarımların artan K değeriyle birlikte düştüğü görülmektedir. (c)’de ise tüm öznitelikler için 45x36 çözünürlüğüne göre ciddi bir değişim gözlenmemektedir.

Şekil 5.12’de 329x264 çözünürlüğünde yapılan deneylerde, ÇB-YİÖ özniteliği hariç diğer tüm öznitelikler için artan K değerleriyle birlikte başarımların düşüş gözlenmiştir.

90x72 ve 329x264 çözünürlüğünde yapılan deney sonuçlarına bakıldığında yaş sınıflandırma başarımlarının çözünürlük arttıkça sürekli olarak artmadığı, belirli bir çözünürlükten sonra sabitlendiği, hatta bu çözünürlükten itibaren yer yer başarımların düşüşlerin yaşandığı gözlemlenmiştir.

K-EYK yaş sınıflandırması genel olarak değerlendirildiğinde ÇB-YİÖ özniteliğinin yaş sınıflandırmasında K-EYK algoritmasıyla birlikte kullanılmaya müsait olmadığı görülmüştür.

5.2.2 RO ile yaş sınıflandırma

RO ile yaş sınıflandırma deneyleri, tıpkı K-EYK deneyleri gibi MORPH ayrık yaş grubu, MORPH iç içe yaş grubu, FG-NET iç içe yaş grubu için üç kez tekrarlanmıştır. Bu deney sonuçları sırasıyla Çizelge 5.6, Çizelge 5.7 ve Çizelge 5.8’de verilmiştir.

Çizelge 5.6: MORPH veri tabanı ayrık yaş grubu için dört farklı özniteliğin, on farklı çözünürlükteki, RO ile yaş sınıflandırma başarımlarının yüzdeleri.

Öznitelik	Boyut									
	2x1	3x2	6x5	8x6	11x9	16x13	22x18	45x36	90x72	329x264
Piksel	%32.2	%31.3	%37.2	%38.4	%38.3	%38.5	%39.3	%39.4	%40.6	%39.9
YİÖ	%29.7	%32.4	%36.5	%34.8	%34.8	%35.8	%35.2	%34.6	%33.5	%32.5
ÇB-YİÖ	-	-	%32.7	%31.8	%32.3	%33.6	%33.7	%37	%40.1	%44.5
HoG	-	-	-	-	-	-	%33.1	%39.8	%44.7	%40.8

Çizelge 5.7: MORPH veri tabanı iç içe yaş grubu için dört farklı öz niteliğin, on farklı çözünürlükteki, RO ile yaş sınıflandırma başarımları yüzdeleri.


Öznitelik	Boyut									
	2x1	3x2	6x5	8x6	11x9	16x13	22x18	45x36	90x72	329x264
Piksel	%43.9	%41.6	%51.1	%51	%52.5	%53.3	%53.9	%54.3	%55	%55.2
YİÖ	%36.9	%43.8	%47.8	%48	%48.7	%48.6	%48.8	%48	%47.4	%44.5
ÇB-YİÖ	-	-	%43.8	%43.8	%43.4	%44.3	%45	%49.6	%54.3	%58.6
HoG	-	-	-	-	-	-	%45.3	%54.6	%59.8	%54.4

Çizelge 5.8: FG-NET veri tabanı iç içe yaş grubu için dört farklı öz niteliğin, on farklı çözünürlükteki, RO ile yaş sınıflandırma başarımları yüzdeleri.

Öznitelik	Boyut									
	2x1	3x2	6x5	8x6	11x9	16x13	22x18	45x36	90x72	329x264
Piksel	%39.9	%40.5	%49.4	%51.7	%54	%56.3	%57.4	%56.8	%58	%57.7
YİÖ	%11.2	%14.7	%14.9	%14.5	%16.5	%16	%15.7	%14.9	%13.4	%12.9
ÇB-YİÖ	-	-	%42	%47.2	%43.5	%47.4	%49.2	%47.1	%46.6	%45.9
HoG	-	-	-	-	-	-	%47.5	%54.4	%56.4	%52.5


Şekil 5.13'te MORPH ayrık yaş grubu, MORPH iç içe yaş grubu ve FG-NET iç içe yaş grubu için RO ile yaş sınıflandırma başarımları yüzde grafikleri verilmiştir.

MORPH Ayrik Yaş Grubu




(a)

MORPH İç İçe Yaş Grubu



(b)

FG-NET İç İçe Yaş Grubu



(c)

Şekil 5.13: On Farklı çözünürlük ve dört farklı öznelik için (a) MORPH ayrik yaş grubu, (b) MORPH iç içe yaş grubu, (c) FG-NET iç içe yaş grubu RO ile yaş sınıflandırma başarımlarında yüzde grafiği.

Şekil 5.13'te RO ile yaş sınıflandırması başarımları grafikleri incelendiğinde, MORPH veri tabanı için en yüksek başarımın, iç içe yaş grubu ve HoG özniteliği kullanıldığında elde edildiği görülmektedir. FG-NET veri tabanı için ise en yüksek başarım piksel parlaklık değeri özniteliği ile elde edilmiş olup, bu başarım MORPH'da elde edilen başarımdan daha düşüktür.

Farklı veri tabanları ve farklı sınıflandırma yöntemleri için ideal özniteliğin değişiklik gösteriyor olması, kullanılacak olan özniteliğin veri seti ve sınıflandırma yöntemine göre şekillenmesi gerektiğini göstermektedir.

RO ve K-EYK ile yaş sınıflandırma sonuçları bir arada incelendiğinde, piksel parlaklık değeri ve HoG özniteliklerinin en yüksek başarımı sağladığı fakat HoG özniteliğinin 22x18 çözünürlüğünden itibaren kullanılabilir olması sebebiyle, piksel parlaklık değerinin yaş tespitinde tek başına yeterli olabileceği görülmüştür. Ayrıca yaş sınıflandırması başarım yüzdesinin, 2x1 çözünürlüğünden itibaren 90x72 çözünürlüğüne kadar yer yer artıp, yer yer sabit kaldığı, 90x72 çözünürlüğünden 329x264 çözünürlüğüne geçildiğinde düştüğü gözlemlenmiştir. Bu yüzden yaş sınıflandırma için en ideal sonuçların 90x72 çözünürlüğüyle elde edileceğini söylemek mümkündür.



6. SONUÇ VE GELECEK ÇALIŞMALAR

Bu tez çalışmasında, 2014 yılında Yasmina Andreu ve arkadaşlarının yaptığı görüntü çözünürlüğünün cinsiyet sınıflandırmasındaki başarısına etkisini inceleyen ve 3x2 çözünürlüğündeki görüntülerde bile cinsiyete ait bilgiler bulunduğunu ortaya koyan çalışmadan [9] ilham alınarak görüntü çözünürlüğünün yaş ve cinsiyet sınıflandırmasındaki başarısına etkisi incelenmiştir. Bu doğrultuda, piksel parlaklık değeri, YİÖ, ÇB-YİÖ ve HoG öznitelik olarak kullanılmış, bu öznitelikler kullanılarak K-EYK ve RO sınıflandırma algoritmaları yardımı ile yaş ve cinsiyet sınıflandırma gerçekleştirilmiştir. Deneylerde MORPH ve FG-NET olmak üzere iki farklı görüntü veri tabanı kullanılmıştır.

Cinsiyet sınıflandırmada, K-EYK kullanılarak MORPH veri tabanına ait görüntülerde yapılan deneylerde, 16x13 çözünürlüğündeki görüntülerde K=1 değeri için %100 başarıma ulaşılmıştır. Fakat veri tabanında aynı kişiye ait birden fazla görüntü bulunması ve görüntüye en yakın görüntünün yine aynı kişiye ait olan görüntü olduğu düşünüldüğünden bu başarı oranının gerçeği çok yansıtmadığı düşünülmektedir. Bu yüzden on farklı K değeri için deneyler tekrarlanmıştır ve K=3, K=5 değerlerinin daha gerçekçi sonuçlar yansıttığı düşünülmektedir. K=3 için maksimum değer olan %98.1'e ve K=5 için maksimum değer olan %97.2'ye 90x72 çözünürlüğünde HoG özniteliği kullanılarak ulaşılmıştır. RO ile cinsiyet sınıflandırmada ise MORPH veri tabanına ait görüntülerde yapılan deneylerde en yüksek başarı oranı olan %88.47'ye, 329x264 çözünürlüğünde piksel parlaklık değerlerinin öznitelik olarak kullanılmasıyla ulaşılmıştır.

Yaş sınıflandırmada, K-EYK kullanılarak MORPH veri tabanına ait görüntülerde yapılan deneylerde, K=3 için maksimum değer olan %90.1'e ve K=5 için maksimum değer olan %86.6'ya, HoG özniteliği ve iç içe yaş grupları kullanılarak ulaşılmıştır. K-EYK kullanılarak FG-NET veri tabanına ait görüntülerde yapılan deneylerde, K=3 için maksimum değer olan %68.4'e ve K=5 için maksimum değer olan %56.3'e, HoG özniteliği ve iç içe yaş grupları kullanılarak ulaşılmıştır. RO ile yaş sınıflandırmada ise MORPH veri tabanına ait görüntülerde yapılan deneylerde en

yüksek başarımlı oranı olan %59.8'e, HoG özneliği ve iç içe yaş grupları kullanılarak ulaşılmıştır. FG-NET veri tabanına ait görüntülerde yapılan yaş sınıflandırması deneylerinde ise en yüksek başarımlı olan %57.7'ye piksel parlaklık değerlerinin öznelik olarak kullanılmasıyla ulaşılmıştır. Yaş sınıflandırma başarımlı yüzdelerinin MORPH veri tabanında daha yüksek olduğu, bu duruma FG-NET veri tabanındaki yaş aralığının MORPH veri tabanındaki yaş aralığına göre çok daha geniş olmasının sebebiyet verdiği düşünülmektedir.

Bu tez çalışmasında elde edilen başarımların, literatürdeki yaş sınıflandırması yapan çalışmaların başarımlarına göre daha düşük olduğu düşünülmüş, bu çalışmalar incelendiğinde kullanılan yöntem ve metotların yeterince açık belirtilmediği, bu yüzden bu çalışmaların birçoğunun “tekrar edilebilirlik” şartını sağlamadığı görülmüştür. Örneğin, 2012 yılında yapılan bir tez çalışmasında [34] Kılınç tarafından yeni bir hibrit sınıflandırma yöntemi önerilmiştir. Bu tez çalışmasında yaş tespitindeki başarımlı Ortalama Tam Hata metriği kullanılarak hesaplanmıştır. Ortalama Tam Hata, gerçek yaş değeri ile tespit edilen yaş değerleri arasındaki farkın ortalaması olarak hesaplanmaktadır. Tez çalışmasında önerilen hibrit sınıflandırma yöntemiyle %5.05 Ortalama Tam Hata payıyla yaş tespitinin gerçekleştirildiği öne sürülmüş fakat hibrit sınıflandırma yönteminin nasıl çalıştığından ve hangi sınıflandırma yöntemlerinin bir araya getirilmesiyle oluşturulduğundan bahsedilmemiştir.

Yaş sınıflandırmasında yüksek başarımlı elde edilen birçok çalışmada kullanılan sınıflandırıcılar incelendiğinde genelde yüksek başarımların K-EYK sınıflandırıcısıyla elde edildiği görülmüştür. Bu çalışmaların sonucunda veri setinin içerisinde aynı kişiye ait farklı fotoğrafların bulunup bulunmadığından bahsedilmemiştir. Bu tez çalışmasında K-EYK sınıflandırıcısı için çok yüksek başarımlar elde edilmesine rağmen, bu başarımlı özel durumları da içerdiğinden (aynı kişiye ait görüntülerin, en yakın görüntüler listesinde bulunması gibi) ve bu özel durumlar gerçek zamanlı problemlerde oluşmayacağından “genelleştirilebilirlik” kriterine aykırı olduğu gerekçesiyle gerçekçi bulunmamış ve başarımlı olarak değerlendirilmeyerek RO sınıflandırıcısı sonuçları daha dikkate değer bulunarak tez çalışmasında bu konuya değinilmiştir. Bu yüzden elde edilen başarımlı, literatürdeki diğer çalışmaların başarımlarına göre nispeten daha düşük olmasına rağmen daha gerçekçi ve güvenilir olduğuna inanılmaktadır.

Gelecekte yapılacak çalışmalarda, pozların, arka planın ve göz orta noktalarının kontrollü olduđu bir veri tabanının kullanılması, K-EYK sınıflandırıcısı için görüntüye en yakın görüntünün yine aynı kişiye ait başka bir görüntü olması durumunda o görüntünün dikkate alınmaması, böylece gerçek hayattaki uygulamalara daha elverişli bir sistem oluşturulması, farklı özniteliklerin incelenerek varsa daha uygun bir öznitelik bulunması ve farklı makine öğrenme algoritmalarının birleştirilerek başarımın artırılması planlanmaktadır. Bu tez çalışmasında, deneyler, yaş oranlarının yanı sıra cinsiyet oranları da korunarak yapılmış fakat yaşlanma süreci kadın ve erkeklerde ayrı ayrı incelenmemiştir. Gelecekte yapılacak çalışmalarda, eğitim ve test kümelerinin farklı cinsiyetler için ayrı ayrı oluşturularak çözünürlüğün yanı sıra cinsiyetin de yaşlanmaya üzerindeki etkisinin incelenmesi planlanmaktadır.



KAYNAKLAR

- [1] “**LaneAssist**”,<http://en.volkswagen.com/en/innovation-and-technology/technical-glossary/spurhalteassistentlaneassist.html>, Alındığı Tarih: 06.07.2016
- [2] “**Automatic Distance Control**”, http://en.volkswagen.com/en/innovation-and-technology/technical-glossary/automatische_distanzregelung_acc.html, Alındığı Tarih: 06.07.2016
- [3] “**Park Assist**”, http://en.volkswagen.com/en/innovation-and-technology/technical-glossary/parklenkassistent_park_assist.html, Alındığı Tarih: 06.07.2016
- [4] “**Google Self-Driving Car**”, <https://www.google.com/selfdrivingcar/>, Alındığı Tarih: 06.07.2016
- [5] “**Kuka Robot**”, <https://www.kuka.com/en-de/about-kuka/brand/timo-boll-the-perfect-match>, Alındığı Tarih: 06.07.2016
- [6] “**Kaave Fali**”, <https://www.kaavefali.com> , Alındığı Tarih: 06.07.2016
- [7] “**Pill Identifier**”, <https://itunes.apple.com/us/app/pill-identifier-by-drugs.com/id398305495?mt=8> , Alındığı Tarih: 06.07.2016
- [8] **Guyuron, B., Rowe, DJ., Winfeld, AB.**, (2009) Factors contribution to the facial aging of identical twins. *Plast Reconstr Surg* 123: 1321-1331.
- [9] **Andreu, Y., López-Centelles, J., Mollineda, R. A., Garcia-Sevilla, P.**, (2014). Analysis of the effect of image resolution on automatic face gender classification. In *Pattern Recognition (ICPR), 2014 22nd International Conference*, IEEE, 273–278.
- [10] **Viola, P., Jones, M. J.**, (2004). Robust real-time face detection. *International journal of computer vision*, 57(2):137–154.
- [11] **Golomb, B. A., Lawrence, D. T., Sejnowski, T. J.**, (1991). Sexnet: A Neural Network Identifies Sex from Human Faces, *Proceedings of the Conference on Advances in Neural Information Processing Systems 3*, 572–579.
- [12] **Tamura, S., Kawai, H., Mitsumoto, H.**, (1996). Male/female identification from 8x6 very low resolution face images by neural network, *Pattern Recogn.*, 29, 331–335.
- [13] **Cortes, C., Vapnik, V.**, (1995). Support-Vector Networks, *Machine Learning*, 20, 273-297.
- [14] **Baluja, S., Rowley, H.**, (2007). Boosting Sex Identification Performance, *IJCV* (2), 111-119.
- [15] **Ma'kinen, E., Raisamo, R.**, (2008). Evaluation of gender classification methods with automatically detected and aligned faces, *IEEE Trans. Pattern Anal. Mach. Intell.*, 30, 3, 541–7.

- [16] **Ravi, S., Wilson, S.,** (2010). Face detection with facial features and gender classification based on support vector machine, Proceedings of IEEE International Conference on Computational Intelligence and Computing Research, 125–130.
- [17] **Khryashchev, S., Priorov A, A., Shmagliti, L., Golubev, M.,** (2012). Gender Recognition via Face Area Analysis, Proc. World Congress on Engineering and Computer Science, Berkeley, USA. P . 645-649.
- [18] **Dey, E. K., Khan, M., Ali, Md. H.,** (2013). Computer Vision-Based Gender Detection from Facial Image. International Journal of Advanced Computer Science 3, 8, 428-433.
- [19] **Geng, X., Zhou, Z-H., Smith-Miles, K.,** (2007). Automatic age estimation based on facial aging patterns. IEEE Trans. on PAMI, 29(12): 2234–2240.
- [20] **Cootes, T.F., Edwards, G.J., Taylor, C.J.,** (1998). Active Appearance Models, Proc. Fifth European Conf. Computer Vision, H. Burkhardt and B. Neumann, eds., vol. 2, pp. 484-498.
- [21] **Txia, J-D., Huang, C-L.,** (2009). Age Estimation Using AAM and Local Facial Features. Fifth International Conference on Intelligent Information Hiding and Multimedia Signal Processing, 885-888.
- [22] **Choi, S. E., Lee, Y. J., Lee, S. J., Park, K. R., Kim, J.,** (2011). Age estimation using a hierarchical classifier based on global and local facial features. Pattern Recogn., 44(6):1262–1281.
- [23] **Guo, G., Wang, X.,** (2012). A study on human age estimation under facial expression changes. In Proc. IEEE CVPR, 2547–2553.
- [24] **Han, H., Otto, C., Jain, A. K.,** (2013). Age Estimation From Face Images: Human vs. Machine Performance, International Conference on Biometrics, ICB 2013, June, 4-7 Madrid, Spain.
- [25] **Du, J-X., Zhai, C-M., Kou, J.,** (2014). Estimating Age Value from Super Resolution Reconstruction Facial Images, 1620-1627. JOURNAL OF COMPUTERS, VOL. 9, NO. 7, JULY.
- [26] **Hayashi, J., Yasumoto, M., Ito, H., Koshimizu, H.,** (2002). Age and gender estimation based on wrinkle texture and color of facial images. In Proc ICPR, pages 405–408.
- [27] **Iga, R., Izumi, K., Hayashi, H., Fukano, G., Ohtani, T.,** (2003). A gender and age estimation system from face images. In Proc. SICE Annual Conference, 756–761.
- [28] **Fukai, H., Takimato, H., Mitsukura, Y., Fukumi, M.,** (2010). Age and Gender Estimation by using Facial Image The 11th IEEE International Workshop on Advanced Motion Control March 21-24, Nagaoka, Japan.
- [29] **Moghaddam, B., Yang, M.,** (2002). Learning gender with support faces, IEEE Trans. Pattern Anal. Mach. Intell., 24, 5, 707–711.
- [30] **El-Din, Y. S., Moustafa, M. N., Mahdi, H.,** (2013). Gender classification using mixture of experts from low resolution facial images, Multiple

Classifier Systems, LNCS, 7872, 49–60.

- [31] **Ricanek Jr, K., Tesafaye, T.,** (2006). Morph: A longitudinal image database of normal adult age-progression. In Automatic Face and Gesture Recognition, FGR 2006.
- [32] **Khryashchev, V., Ganin A., Stepanova, O., Lebedev, A.,** (2014). Age estimation from face images: challenging problem for audience measurement systems. In Open Innovations Association (FRUCT16), 2014 16th Conference of, 31–37. IEEE.
- [33] **Breiman, L., Schapire, E.,** (2001). Random Forests, Machine Learning, 5-32.
- [34] **Kılınç, M.,** (2012). Yüz Resimlerinden Yaş Bilgisinin Tespit Edilmesi. Gebze Teknik Üniversitesi.





ÖZGEÇMİŞ

Ad-Soyad : Betül CERİT
Uyruğu : T.C
Doğum Tarihi ve Yeri : 31.01.1989 - ESKİŞEHİR
E-posta : betulceritt@gmail.com

ÖĞRENİM DURUMU:

- **Lisans** : 2010, Yakın Doğu Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2011-2015	Netgsm İletişim ve Bilgi Teknolojileri A.Ş	Bilgisayar Mühendisi

YABANCI DİL: İNGİLİZCE

TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Cerit, B.**, Bölük, S. A., Demirci, M. F., 2016. Analysis of the Effect of Image Resolution on Automatic Face Gender and Age Classification, SIU 2016, 853-856.